

6

Département de géographie et télédétection  
Faculté des lettres et sciences humaines  
Université de Sherbrooke

# Élaboration d'un système à base de règles pour l'identification des zones perturbées en milieu forestier

Yves VOIRIN

Thèse présentée pour l'obtention du grade  
de Philosophiae Doctor (Ph.D.) en télédétection

Décembre 2004

©VOIRIN, 2004

I-2104

## Résumé

La gestion d'un territoire forestier exige régulièrement une mise à jour de cartes. Cette actualisation peut s'effectuer automatiquement grâce aux techniques de détection du changement. La procédure s'accomplit en plusieurs étapes, où chacune d'entre elles risque d'introduire des erreurs. La carte finale comporte alors de nombreuses fausses alarmes qui doivent être corrigées pour obtenir un document fiable. C'est pourquoi la méthode traditionnelle par photo-interprétation est souvent préférée, car l'interprète effectue avec une plus grande précision l'identification des zones réellement perturbées. Lors de cette procédure, l'interprète utilise divers paramètres, tels que la texture, l'aspect, le contexte spatial mais aussi sa connaissance sur la région. Afin de reproduire automatiquement ce travail, il est donc nécessaire de développer une démarche similaire en utilisant une approche par région (aussi appelée orientée objet). De plus, l'intégration d'informations issues de la connaissance nécessite l'utilisation de méthodes dites intelligentes. Ces méthodes permettent d'intégrer dans l'analyse les attributs de chaque région ainsi que la connaissance spécifique à l'application. Il existe deux groupes de méthodes, celles dont l'apprentissage est pratiqué avec une base d'exemples, telles que l'arbre de décision C4.5 ou le réseau de neurones Perceptron multi-couches (PMC), et celles dont l'apprentissage est dirigé par l'utilisateur, telles que le système à base de règles (JESS). Les systèmes intelligents ont déjà été utilisés dans le cadre de la mise à jour de cartes forestières. Malheureusement ce type d'approche n'a jamais dépassé l'étape du prototype.

Le travail de cette thèse consiste à évaluer l'association d'une méthode classique et d'un système à base de règles. Cette association permet de réduire la complexité du problème à résoudre. En effet, le système intelligent doit uniquement raisonner sur les cas critiques relevés par la méthode classique. Dans le contexte d'une identification du changement en milieu forestier, une analyse post-classification est combinée avec le système expert JESS. Le système proposé a été testé sur un site d'étude au Labrador. Les résultats obtenus sont supérieurs à ceux des méthodes conventionnelles de détection du changement et des méthodes C4.5 et PMC. Le système JESS permet d'intégrer de nombreuses règles sur le contexte spatial, les transitions temporelles et les indices de végétation. La combinaison de toutes ces informations dans un même système surclasse toutes les autres méthodes évaluées. Par ailleurs, l'approche développée peut être reproduite pour une nouvelle mise à jour sans aucune modification.



### Abstract

Natural resources management has become an important topic concerning the environment. Sound management encourages the protection of our environment and supports sustainable development. Policies and regulations regarding the environment require the development of monitoring systems. Remote sensing technologies are important tools in the elaboration of these systems. Regional monitoring permits resource managers to obtain accurate information on the status of these resources. Based on this information, it is possible to plan actions contributing to the preservation of the environment.

In this context, forest region monitoring requires the updating of forestry maps. The update can take place automatically with the assistance of change detection methods. The procedure takes place in several stages, where the possibility of introducing errors at each step exists. The final map may subsequently include numerous false alarms that must be corrected in order to obtain a reliable document. The traditional method is often preferred, because the interpreter identifies truly disturbed areas with great precision. According to the visual interpretation, the photo-interpreter uses various criteria, such as texture, appearance or context of the area to be identified. In order to reproduce this work automatically, it is necessary to develop a similar approach, such as an oriented-object method. In addition, the integration of information similar to that of the interpreter requires the use of intelligent methods. At the present time, these methods analyse the attributes of each object more accurately than conventional methods. In this case two groups of methods are distinguished; those based on the case-based reasoning (CBR), such as decision trees or neural networks; and those whose learning is supervised by the user, known as experts systems (ES).

For change identification in forest region, a method applying the second approach is preferred. A rule-based system has been elaborated for a study site in Labrador. Results of this approach reveal that the system provides more accurate results than the methods of the first approach. Indeed, the first group of methods depends on the samples. Otherwise, the rule-based system permits the conservation of the done work.

## Remerciements

D'abord, je tiens à remercier mes codirecteurs, Pr. Goze Bertin Béné et Pr. Dong-Chen He, qui ont accepté de diriger ma thèse. Je remercie également tous les membres de l'équipe ESTRITEL pour leur aide pendant ce travail. Je tiens à remercier toute ma famille pour leur soutien et leurs encouragements.

Je souhaite remercier en particuliers, mon ami, Matthieu, pour son importante contribution dans la formidable aventure du projet Siti. Je terminerais ces remerciements par témoigner toute ma gratitude à Samira pour son aide considérable.

## Table des matières

|   |           |
|---|-----------|
| Résumé . . . . .  | ii        |
| Abstract . . . . .  | iii       |
| Remerciements . . . . .   | iv        |
| Liste des figures . . . . .   | viii      |
| Liste des tableaux . . . . .  | ix        |
| Liste des annexes . . . . .   | x         |
| Liste des sigles . . . . .  | xi        |
| Liste des symboles . . . . .  | xii       |
| <b>1. Introduction . . . . .</b>  | <b>1</b>  |
| 1.1. Contexte . . . . .   | 1         |
| 1.1.1. La gestion des ressources naturelles . . . . .                       | 1         |
| 1.1.2. Une technologie qui s'améliore . . . . .                             | 2         |
| 1.1.3. Vers des systèmes de traitement d'images plus intelligents . . . . . | 3         |
| 1.2. Problématique de la recherche . . . . .                                | 5         |
| 1.3. Objectifs et originalités . . . . .                                    | 6         |
| 1.3.1. Finalité du projet . . . . .   | 6         |
| 1.3.2. But de la thèse . . . . .  | 7         |
| 1.3.3. Objectifs spécifiques . . . . .                                      | 7         |
| 1.3.4. Originalité . . . . .  | 7         |
| 1.4. Hypothèses de la recherche . . . . .                                   | 8         |
| 1.4.1. Hypothèse liée à l'identification . . . . .                          | 8         |
| 1.4.2. Hypothèse liée au système à base de règles . . . . .                 | 8         |
| 1.4.3. Hypothèse liée à la détection du changement . . . . .                | 9         |
| 1.5. Présentation du plan de la thèse . . . . .                             | 9         |
| <b>2. Revue des travaux antérieurs . . . . .</b>                            | <b>10</b> |
| 2.1. Principes de détection et d'identification du changement . . . . .     | 10        |
| 2.1.1. Information ou données ? . . . . .                                   | 10        |
| 2.1.2. Définition du changement . . . . .                                   | 10        |
| 2.1.3. Procédure classique de détection du changement . . . . .             | 11        |

|  |           |
|--|-----------|
| 2.1.4. L'interprétation des zones changées . . . . .                                   | 13        |
| 2.2. Les méthodes automatiques . . . . .   | 14        |
| 2.2.1. Les méthodes de détection du changement . . . . .                               | 15        |
| 2.2.2. L'identification automatique . . . . .  | 21        |
| 2.3. Limites des méthodes automatiques . . . . .                                       | 22        |
| 2.3.1. La nature des données . . . . .   | 22        |
| 2.3.2. Les méthodes de classification . . . . .  | 24        |
| 2.3.3. L'identification automatique . . . . .  | 24        |
| 2.4. Récents développements . . . . .  | 25        |
| 2.5. L'interprétation de données de télédétection à l'aide de systèmes de décision . . | 27        |
| 2.5.1. Définitions dans le domaine de l'intelligence artificielle . . . . .            | 27        |
| 2.5.2. Revue des travaux en télédétection . . . . .                                    | 28        |
| 2.5.3. Principe général de l'interprétation automatique . . . . .                      | 32        |
| 2.5.4. L'approche orientée objet . . . . .   | 33        |
| 2.5.5. Le choix de l'apprentissage . . . . .   | 34        |
| 2.5.6. Quelques systèmes de décision . . . . .   | 36        |
| 2.6. Conclusion partielle . . . . .  | 51        |
| <b>3. Développements méthodologiques . . . . .</b>                                     | <b>53</b> |
| 3.1. Méthodologie générale . . . . .   | 53        |
| 3.2. L'approche pour la détection du changement . . . . .                              | 55        |
| 3.3. L'approche orientée objet . . . . .   | 57        |
| 3.3.1. La création des régions . . . . .   | 57        |
| 3.3.2. Les attributs des régions . . . . .   | 58        |
| 3.4. Le système à base de connaissances . . . . .                                      | 63        |
| 3.4.1. Représentation symbolique d'un objet . . . . .                                  | 64        |
| 3.4.2. La création de la base de règles . . . . .                                      | 65        |
| 3.4.3. Mécanisme de raisonnement . . . . .   | 69        |
| 3.5. Élaboration des règles pour l'identification du changement . . . . .              | 69        |
| 3.5.1. Règles simples sur un attribut . . . . .  | 70        |
| 3.5.2. Règles sur le contexte spatial . . . . .  | 71        |
| 3.5.3. Règles sur les sites d'entraînement . . . . .                                   | 71        |
| 3.5.4. Règles sur l'occupation du sol . . . . .  | 73        |
| 3.5.5. Règles sur les erreurs . . . . .  | 74        |
| 3.6. Les systèmes basés sur l'apprentissage par l'exemple . . . . .                    | 75        |
| 3.6.1. La représentation de l'objet . . . . .  | 75        |
| 3.6.2. Problème de la définition des classes . . . . .                                 | 75        |



|   |            |
|---|------------|
| 3.6.3. La sélection des exemples . . . . .                              | 76         |
| 3.6.4. La considération du contexte spatial . . . . .                   | 76         |
| 3.6.5. Choix relatifs à l'arbre de décision . . . . .                   | 77         |
| 3.6.6. Choix relatifs au réseau de neurones . . . . .                   | 77         |
| 3.7. L'évaluation des résultats . . . . .                               | 78         |
| 3.7.1. Les critères . . . . .   | 78         |
| 3.7.2. Les Études . . . . .   | 81         |
| 3.8. Conclusion partielle . . . . .                                     | 83         |
| <b>4. Application . . . . .</b>   | <b>85</b>  |
| 4.1. Les ensembles de données . . . . .                                 | 85         |
| 4.1.1. Les images artificielles . . . . .                               | 85         |
| 4.1.2. Les données réelles . . . . .                                    | 86         |
| 4.2. Choix méthodologiques . . . . .                                    | 95         |
| 4.2.1. Les approches classiques . . . . .                               | 95         |
| 4.2.2. Méthodes d'optimisation de résultat de classification . . . . .  | 96         |
| 4.3. Présentation et analyse des résultats . . . . .                    | 97         |
| 4.3.1. Évaluation du système sur les données simulées . . . . .         | 97         |
| 4.3.2. Résultats sur les données réelles à moyenne résolution . . . . . | 110        |
| 4.3.3. Résultats préliminaires sur la très haute résolution . . . . .   | 133        |
| 4.4. Conclusion partielle . . . . .                                     | 136        |
| <b>5. Conclusions et recommandations . . . . .</b>                      | <b>139</b> |
| 5.1. Recherche effectuée . . . . .                                      | 139        |
| 5.2. Limitations . . . . .  | 141        |
| 5.3. Recommandations . . . . .  | 141        |
| 5.4. Perspectives . . . . .   | 142        |
| 5.4.1. Erreurs dues aux corrections . . . . .                           | 142        |
| 5.4.2. Les images à très haute résolution spatiale . . . . .            | 142        |
| 5.4.3. L'analyse multirésolution . . . . .                              | 143        |
| 5.4.4. Plus d'informations . . . . .                                    | 143        |
| 5.4.5. La création des règles . . . . .                                 | 144        |
| 5.4.6. Les règles floues . . . . .                                      | 144        |
| 5.4.7. D'autres applications . . . . .                                  | 145        |
| <b>6. Références . . . . .</b>  | <b>146</b> |

## Liste des figures

|      |  |     |
|------|--|-----|
| 2.1  | Méthode de mise à jour par image satellitaire, source : (Matejek, 1997) . . . . .                | 12  |
| 2.2  | Détection du changement par régression linéaire . . . . .  | 17  |
| 2.3  | Représentation du vecteur de changement ( $m = 2$ ) . . . . .                                    | 17  |
| 2.4  | La même région vue par Ikonos et Landsat TM . . . . .  | 23  |
| 2.5  | Processus de reconnaissance automatique . . . . .  | 32  |
| 2.6  | L'objet et ses attributs . . . . .   | 34  |
| 2.7  | Architecture générale . . . . .  | 37  |
| 2.8  | Exemple d'un arbre de décision . . . . .   | 43  |
| 2.9  | Illustration de l'approximation des ensembles par l'arbre . . . . .                              | 46  |
| 2.10 | Exemple d'un réseau de neurones . . . . .  | 48  |
| 2.11 | Approximation par le réseau de neurones . . . . .  | 49  |
| 2.12 | Réseau de neurones avec une couche cachée, 5 neurones cachés (à gauche) et 9 (à droite). . . . . | 50  |
| 3.1  | Démarche conceptuelle . . . . .  | 54  |
| 3.2  | Procédure de mise à jour . . . . .   | 56  |
| 3.3  | Création des segments . . . . .  | 57  |
| 3.4  | Les indicateurs de végétation verte et de brillance du sol . . . . .                             | 61  |
| 3.5  | Variations des indices NDVI et ARVI sur les classes thématiques du Labrador . . . . .            | 62  |
| 3.6  | Méthode de détermination de la classe de l'indice . . . . .                                      | 71  |
| 3.7  | Les sites d'entraînement . . . . .   | 72  |
| 3.8  | Exemple de cycle du changement . . . . .   | 74  |
| 3.9  | Procédure pour déterminer le réseau . . . . .  | 79  |
| 4.1  | Données simulées . . . . .   | 86  |
| 4.2  | Localisation des sites d'étude . . . . .   | 87  |
| 4.3  | Image LANDSAT-7 (ETM) de Juillet 2000 . . . . .  | 88  |
| 4.4  | Suivi des zones changées avec les images LANDSAT, composé coloré (5,4,3) . . . . .               | 90  |
| 4.5  | Ensemble de données à moyenne résolution spatiale . . . . .                                      | 91  |
| 4.6  | Image Ikonos de 2001 (canaux RGB) . . . . .  | 92  |
| 4.7  | Comparaison des différentes approches (image fortement bruitée) . . . . .                        | 101 |
| 4.8  | Influence des règles sur le résultat (image fortement bruitée) . . . . .                         | 105 |
| 4.9  | Influence des règles sur le résultat (image fortement bruitée) . . . . .                         | 107 |
| 4.10 | Temps de raisonnement en fonction des règles . . . . .   | 108 |
| 4.11 | Approche par pixel . . . . .   | 108 |
| 4.12 | Influence du choix du seuil sur les taux (méthode ACC) . . . . .                                 | 113 |

|      |  |     |
|------|--|-----|
| 4.13 | Résultats des différentes méthodes de détection du changement . . . . .    | 114 |
| 4.14 | Résultats de l'identification des zones changées . . . . .                 | 115 |
| 4.15 | Ensemble de données pour APC . . . . .                                     | 118 |
| 4.16 | Mise à jour de la carte de 1989 . . . . .                                  | 119 |
| 4.17 | Influence des règles sur le résultat . . . . .                             | 122 |
| 4.18 | Confiance sur l'identification . . . . .                                   | 123 |
| 4.19 | Influence d'une mauvaise règle . . . . .                                   | 125 |
| 4.20 | Résultats de l'application de la base . . . . .                            | 127 |
| 4.21 | Résultats des autres approches intelligentes sur l'image de 1999 . . . . . | 130 |
| 4.22 | Précision en fonction du nombre d'exemples . . . . .                       | 131 |
| 4.23 | Résultats du réseau de neurones . . . . .                                  | 132 |
| 4.24 | Comparaison des méthodes cognitives sur Ikonos . . . . .                   | 137 |
| 6.1  | Chargement des images . . . . .  | 165 |
| 6.2  | Onglet pour la description . . . . .                                       | 166 |
| 6.3  | Choix des paramètres . . . . .   | 167 |
| 6.4  | Les indices de végétation . . . . .  | 168 |
| 6.5  | Sélection d'une région . . . . .   | 169 |
| 6.6  | Éditeur de légende . . . . .   | 169 |
| 6.7  | Un résultat . . . . .  | 170 |

## Liste des tableaux

|     |   |     |
|-----|---|-----|
| 2.1 | Applications des réseaux les plus connus . . . . .                      | 47  |
| 3.1 | La base d'exemples . . . . .  | 75  |
| 3.2 | Deux approches pour définir les classes . . . . .                       | 76  |
| 3.3 | La base d'exemples avec contexte spatial . . . . .                      | 77  |
| 3.4 | Matrice de confusion . . . . .  | 79  |
| 4.1 | Rapport signal sur bruit pour chaque image . . . . .                    | 85  |
| 4.2 | Données disponibles pour l'étude . . . . .                              | 89  |
| 4.3 | Séparabilité des classes pour l'image Landsat de Juillet 1999 . . . . . | 94  |
| 4.4 | Résultats de la détection pour les images simulées (en %) . . . . .     | 98  |
| 4.5 | Résultats obtenus sur les données simulées(en %) . . . . .              | 99  |
| 4.6 | Résultats de l'identification sur les images simulées (en %) . . . . .  | 99  |
| 4.7 | Résultats du système à base de règles (en %) . . . . .                  | 100 |
| 4.8 | Sensibilité aux facteurs de certitude pour l'image 1(en %) . . . . .    | 102 |

|      |  |     |
|------|--|-----|
| 4.9  | Sensibilité aux facteurs de certitude pour l'image 2(en %)                                     | 103 |
| 4.10 | Sensibilité aux règles pour l'image 1(en %)  | 104 |
| 4.11 | Sensibilité aux règles pour l'image 2(en %)  | 104 |
| 4.12 | Résultats de la détection sur les données réelles (en %)                                       | 112 |
| 4.13 | Résultats de l'identification (en %)   | 116 |
| 4.14 | Résultats obtenus avec la classification sur les données réelles (en %)                        | 117 |
| 4.15 | Résultats obtenus avec le système à base de règles (en %)                                      | 119 |
| 4.16 | Résultats du système avec les données réelles (en %)   | 121 |
| 4.17 | Sensibilité au facteur de certitude (en %)   | 124 |
| 4.18 | Résultats de l'approche modifiée pour les images LANDSAT 2000 et 2001 (en %)                   | 126 |
| 4.19 | Résultats de l'APC classique pour les images LANDSAT 2000 et 2001 (en %)                       | 128 |
| 4.20 | Résultats obtenus avec les autres méthodes intelligentes sur l'image LANDSAT<br>de 1999 (en %) | 129 |
| 4.21 | Résultats obtenus avec le réseau de neurones (en %)  | 132 |
| 4.22 | Résultats de l'approche APC (en %)   | 135 |
| 4.23 | Résultats des différentes méthodes cognitives (en %)   | 135 |

## Liste des annexes

|  |            |
|--|------------|
| <b>Annexe I : La base de connaissances pour la moyenne résolution au Labrador</b>                | <b>158</b> |
| <b>Annexe II : Quelques exemples de règles en CLIPS</b>  | <b>161</b> |
| <b>Annexe III : Manuel pour le logiciel d'interprétation assistée par un système intelligent</b> | <b>164</b> |



## Liste des sigles

|          |  |
|----------|--|
| ACC      | Analyse par corrélation croisée                                |
| ACP      | Analyse en composantes principales                             |
| APC      | Analyse post-classification                                    |
| ARVI     | Atmospherically Resistant Vegetation Index                     |
| ASTER    | Advanced Spaceborne Thermal Emission and Reflection Radiometer |
| AVHRR    | Advanced Very High Resolution Radiometer                       |
| C4.5     | Extension de la méthode ID3                                    |
| CASI     | Compact Airborne Spectrographic Imager                         |
| CCT      | Centre Canadien de Télédétection                               |
| CLIPS    | C Language Integrated Production System                        |
| IA       | Intelligence Artificielle                                      |
| ICM      | Iterative Conditional Mode                                     |
| ID3      | Iterative Dichotomizer version 3                               |
| Ikonos   | Satellite de la société SPACE IMAGING                          |
| JESS     | Java Expert System Shell                                       |
| Landsat  | Satellite à moyenne résolution spatiale                        |
| MLP      | Multi Layer Perceptron   |
| MNA      | Modèle Numérique d'Altitude                                    |
| MYCIN    | Mycin expert system  |
| NDVI     | Normalized Difference Vegetation Index                         |
| Radarsat | Satellite canadien avec un capteur radar                       |
| RVB      | Rouge-Vert-Bleu  |
| SE       | Système expert   |
| SIG      | Système d'information géographique                             |

## Liste des symboles

|                    |  |
|--------------------|--|
| $a$                | valeur d'activation  |
| $f()$              | fonction d'activation                                      |
| $i$                | numéro du neurone (couche cachée + entrée)                 |
| $j$                | numéro du neurone (couche sortie)                          |
| $M$                | nombre de neurones sur une couche                          |
| $w_i$              | poids du neurone $i$                                       |
| $f_i$              | valeur d'activation du neurone $i$                         |
| $P$                | nombre d'exemples présentés à la méthode                   |
| $S$                | nombre de neurones de la couche de sortie                  |
| $p$                | numéro de l'exemple  |
| $t_j^p$            | sortie désirée pour l'exemple $p$ et neurone de sortie $j$ |
| $\sigma_j^p$       | sortie obtenue pour l'exemple $p$ et neurone de sortie $j$ |
| $W$                | matrice des poids  |
| $\nabla Etot$      | gradient de l'erreur globale                               |
| $\eta$             | taux d'apprentissage                                       |
| $\alpha$           | taux pour le momentum                                      |
| $m$                | nombre d'informations                                      |
| $n$                | dimension de l'espace                                      |
| $Z_{jk}$           | la valeur du pixel d'indice $(j,k)$                        |
| $i$                | la bande considérée  |
| $N_b$              | le nombre de bandes  |
| $c_{jk}$           | la classe thématique (ancienne classe)                     |
| $r_{ijk}$          | la réflectance du pixel                                    |
| $\mu_{ic}$         | la moyenne de la classe $c$ dans la bande $i$              |
| $\sigma_{ic}$      | l'écart-type de la classe $c$ dans la bande $i$            |
| $\vec{x}, \vec{y}$ | vecteurs de caractéristiques                               |
| $C$                | matrice de covariance                                      |
| $D_{Mahalanobis}$  | distance de Mahalanobis                                    |

# 1. Introduction

## 1.1. Contexte

### 1.1.1. La gestion des ressources naturelles

La préservation de l'environnement semble être l'enjeu majeur de ces dernières décennies. Les bouleversements climatiques et les catastrophes écologiques démontrent la nécessité de mettre en place des mesures pour la protection de la nature. Elles se traduisent, tant au niveau du globe (protocole de Kyoto) qu'au niveau d'une région, par l'instauration de politiques et de réglementations notamment sur :

- la gestion des ressources naturelles renouvelables ou non (eau, matières premières, ... ) ;
- la gestion des déchets (matières dangereuses, ... ) ;
- la qualité de l'air.

Les lois sur l'environnement permettent de poursuivre pénalement les contrevenants. L'instauration d'amendes lourdes dissuade ceux-ci de certaines pratiques abusives, comme le dégazage de pétroliers. Cependant, la résolution des problèmes environnementaux ne doit pas être seulement législative. La prévention doit être préférée, notamment avec des systèmes de surveillance et d'alerte. Des approches existent déjà en foresterie et en agriculture (Jain *et al.*, 1996; Fernandez *et al.*, 1997; Moran *et al.*, 1997; Aguado *et al.*, 2003). La télédétection est un outil idéal pour l'élaboration de systèmes de surveillance, car :

- elle fournit une information actualisée quotidiennement ou mensuellement, selon la fréquence de passage de la plate-forme ;
- les données peuvent être combinées entre elles et ce, à l'intérieur d'un système d'informations géographique (SIG) ;

- elle permet d’acquérir des données indépendamment des conditions atmosphériques grâce au radar ;
- elle permet d’obtenir une grande quantité d’information rapidement sur une grande étendue spatiale.

Ces quelques avantages confèrent à la télédétection une utilisation dans de nombreux projets environnementaux, comme la surveillance des désastres naturels. En 1997, le centre canadien de télédétection a notamment utilisé des images RADARSAT-1 pour évaluer les régions touchées par l’inondation de la rivière Rouge au Manitoba. Par ailleurs, le projet FIRE M3 illustre l’utilisation de la télédétection pour le suivi des feux de forêt au Canada (Canada, 2004).

À un niveau local, la baisse des coûts relatifs à la télédétection, notamment au niveau du matériel et des données, laisse entrevoir le développement de systèmes de gestion destinés à l’usage de compagnies privées.

### **1.1.2. Une technologie qui s’améliore**

Depuis l’apparition de la photographie aérienne, le nombre de capteurs dévolus à la gestion des ressources naturelles n’a cessé d’augmenter. Le Canada dispose aujourd’hui des dizaines de capteurs aéroportés et une vingtaine de capteurs spatiaux de télédétection (Sources : Environnement Canada et (Bakker, 2002)). Ils permettent d’obtenir de l’information à différentes résolutions, depuis la très haute (Compact Airborne Spectrographic Imager (CASI), limite de résolution spatiale de 1 m), jusqu’à la basse (AVHRR, limite de résolution spatiale de 1.1 km). Ces capteurs couvrent différentes parties du spectre (ex : visible, infrarouge ou encore micro-ondes).



Cette gamme s'est enrichie dernièrement de capteurs satellitaires à très haute résolution spatiale, comme Ikonos et Quickbird. Ce type de capteur offre une information à une résolution proche de celle de la photographie. La précision spatiale est tellement grande que l'on peut parler d'information au niveau de l'arbre (Fournier *et al.*, 1995; Martin *et al.*, 1998; Quackenbush *et al.*, 2000).

Parallèlement aux développements de l'instrumentation, de nouvelles méthodes pour exploiter les données sont apparues. Il s'agit de la combinaison d'information provenant, soit du même capteur dans différentes configurations, soit de deux capteurs différents. Cette approche permet d'envisager de multiples associations et d'extraire de nouvelles caractéristiques de la surface. Par exemple, la combinaison d'informations radar et optique permet d'obtenir l'humidité et la rugosité (Moran *et al.*, 1997). Ces deux paramètres peuvent être introduits dans des modèles caractérisant la végétation.

Avec l'annonce du lancement prochain de RADARSAT-2, le Canada propose un capteur qui permettra l'acquisition d'une scène dans différentes polarisations. Les contraintes liées à l'utilisation de deux capteurs radar sont alors inexistantes. Ce nouveau type de capteur a un intérêt dans l'estimation de l'humidité et en interférométrie (Dubois *et al.*, 1995; Neusch et Sties, 1999; Okhimamhe, 2003).

L'amélioration continue, tant au niveau du matériel que de l'exploitation de l'information, permet l'utilisation de la télédétection dans de nouvelles applications. On peut citer comme exemple l'utilisation de l'imagerie radar comme l'alternative des images optiques dans le suivi de la déforestation des zones tropicales (Salas *et al.*, 2002).

### **1.1.3. Vers des systèmes de traitement d'images plus intelligents**

Plusieurs facteurs contribuent au développement de nouvelles méthodes d'analyse d'image en télédétection. Premièrement, l'augmentation des performances du matériel informatique

permet l'élaboration de méthodes qui autrefois n'étaient pas envisageables (les méthodes d'intelligence artificielle étaient coûteuses en temps de traitement). Deuxièmement, les méthodes classiques montrent des limites dans l'exploitation des nouveaux types de capteur, c'est notamment le cas pour le radar et les images à très haute résolution spatiale (Kontoes *et al.*, 2000).

Les nouvelles approches d'analyse d'image en télédétection se répartissent selon les axes suivants :

- la logique floue (Lin et Yu, 2004) ;
- la fusion d'informations (Germain *et al.*, 2003) ;
- l'intelligence artificielle (IA) (Zhou *et al.*, 2003; Liu et Zhou, 2004).

Chacun de ces axes contribue à l'intégration de nouveaux concepts en analyse d'image. La logique floue est différente de la logique classique (booléenne) et permet le traitement d'une information plus incertaine. Elle exploite le principe d'incertitude et d'imprécision de l'information. Dans un même registre, les méthodes de fusion combinent judicieusement l'information de différentes sources pour en tirer une décision plus précise. Ces méthodes prennent aussi en compte l'incertitude de l'information de chaque source. La théorie des probabilités (règle de Bayes) et celle des croyances (fonction de Shafer) permettent de formaliser le processus de fusion. Ces deux approches tendent à reproduire le comportement humain face à une décision, mais elles n'en traduisent pas tous les aspects. D'une part, les notions d'expérience et d'acquisition de la connaissance ne sont pas prises en compte dans ces théories ; d'autre part elles ne permettent pas l'intégration d'informations symboliques, comme un terme spécifique au domaine d'application. L'IA peut apporter une solution à ce genre de problème, c'est pourquoi on la retrouve dans de multiples champs d'étude tels que :

- l’interprétation de données (Mulder *et al.*, 1991; Clement *et al.*, 1993; Fung *et al.*, 1993; Hartog *et al.*, 1996; McKeown, 1996; Abkar *et al.*, 2000; Sester, 2000) ;
- les outils de classification (Moller-Jensen, 1990; Rollet *et al.*, 1998; Soh *et al.*, 2004) ;
- la modélisation (Jiang, 2000; Raney et Nagel, 2003).

L’IA est considérée comme une alternative aux méthodes classiques, lorsque le problème est difficilement modélisable ou qu’une solution algorithmique n’est pas forcément possible. Bien que la plupart des méthodes d’IA existent depuis les années 60, leur application en télédétection a réellement débuté il y a une vingtaine d’années.

## 1.2. Problématique de la recherche

La conception d’une carte est traditionnellement réalisée par l’interprétation de photographies. Cette technique permet d’atteindre la précision souhaitée pour les cartes à grande échelle (1 :10 000 - 1 :50 000). Si le territoire à surveiller devient trop important, l’utilisation d’images satellitaires semble alors une bonne alternative aux photographies. Bien que l’interprète dispose de plus en plus d’assistance informatisée, la réalisation d’une carte demeure encore une procédure coûteuse en temps.

La mise à jour d’une carte est généralement réalisée selon une procédure, qui nécessite plusieurs étapes, depuis la correction des données jusqu’à la recherche des zones changées et leur identification. Certaines étapes peuvent être automatisées ou au moins assistées par un ordinateur. La plupart des travaux décrits dans la littérature sont basés sur la détection automatique des zones changées. Une revue des méthodes existantes peut être trouvée dans (Coppin et Bauer, 1996). Malheureusement, le résultat des méthodes actuelles dépend fortement des erreurs commises lors de la procédure. Un manque de précision dans les corrections entraîne une mauvaise détection des zones changées. Finalement, l’accumulation des erreurs au fil des étapes rend inefficace les méthodes d’identification classiques, telles que

les méthodes statistiques de classification. L'utilisateur a la possibilité de réduire certaines de ces erreurs. Par exemple, il peut refaire les corrections avec une plus grande précision, ou si la procédure nécessite un outil de classification, il peut choisir un autre algorithme ou faire un post-traitement. Malgré cela, la qualité du résultat final est encore très dépendante des erreurs commises dans les différents traitements.

Généralement, les limitations des méthodes classiques sont dues à l'analyse par pixel des données et au manque d'information spécifique (Walter, 2004). Or, la technique d'interprétation visuelle nous apprend qu'il faut considérer la région à identifier selon plusieurs critères, tels que la forme et le contexte spatial. Par ailleurs, l'interprète utilise son expérience et sa connaissance pour reconnaître les éléments présents dans une image. Cette connaissance est généralement exprimée sous forme de clés d'interprétation. L'intégration des critères et de la connaissance nécessite de mettre en place de nouvelles méthodes d'analyse d'image basées sur l'IA (Fung *et al.*, 1993). En effet, ces méthodes offrent généralement une alternative aux méthodes conventionnelles. En reconnaissance de forme, les méthodes cognitives sont une solution intéressante, car elles intègrent divers types d'information et permettent de gérer la connaissance.

### **1.3. Objectifs et originalités**

#### **1.3.1. Finalité du projet**

Le travail de cette thèse est une composante du projet SITI (Système Intelligent de Traitement d'Image). La finalité de ce projet est la mise en place d'un système de gestion forestière à l'aide de données de télédétection pour le territoire du Grand Nord.



### 1.3.2. But de la thèse

Le but de cette thèse est d'élaborer un système à base de règles pour l'identification automatique des zones perturbées en milieu forestier.

### 1.3.3. Objectifs spécifiques

Les objectifs spécifiques sont les suivants :

- intégrer dans un même système, des informations spatiales et non spatiales (connaissances) ;
- identifier les coupes et les zones en régénération parmi les fausses alarmes avec des données à moyenne ou à très haute résolution ;
- mettre en place une approche orientée objet pour utiliser les mêmes critères que l'interprétation visuelle ;
- comparer l'apprentissage supervisé du système expert à l'apprentissage par l'exemple, grâce à un arbre de décision ou un réseau de neurones.

### 1.3.4. Originalité

Le travail réalisé dans cette thèse propose une application originale des systèmes intelligents à la télédétection. En effet, un système à base de règles, un réseau de neurones et un arbre de décision sont comparés dans cette étude. L'évaluation de ces trois approches est rarement faite dans une même étude. De plus, les approches développées dans cette thèse peuvent être adaptées à d'autres problématiques.

Bien que des travaux antérieurs aient montré l'intérêt d'utiliser des systèmes à base de règles dans différents domaines de recherche, ils n'ont jamais réellement été évalués dans le contexte

d'une mise à jour de carte. Parmi les travaux précédents, certains tentaient d'utiliser directement le système intelligent sur les données brutes (Goldberg *et al.*, 1985; Goodenough *et al.*, 1989; Tsatsoulis, 1993). Or, il apparaît que l'élaboration d'un tel système pour l'interprétation de données requiert la considération de nombreux paramètres, comme la variabilité de l'information. La complexité de ces systèmes a donc rendu leur exploitation difficile et ils demeurent à l'état de prototype. Par conséquent, l'association d'un système expert et d'une procédure existante, à savoir l'analyse post-classification, semble être une approche innovatrice et prometteuse.

Finalement, l'approche développée dans cette étude est aussi une orientation possible pour l'utilisation des données à très haute résolution spatiale (Ikonos) dans la détection du changement. Peu d'études utilisent ce type de données dans ce contexte.

## **1.4. Hypothèses de la recherche**

### **1.4.1. Hypothèse liée à l'identification**

Nous supposons que la combinaison de l'information issue des images et de la connaissance spécifique à l'application permet de mieux identifier les régions présentes dans une scène.

### **1.4.2. Hypothèse liée au système à base de règles**

Afin de réaliser l'identification des zones changées, nous supposons que la connaissance issue, entre autres, de la littérature sur le détection du changement et de l'analyse d'image, peut être traduite dans une base de règles. Par ailleurs, nous présumons que le système à base de règles permet de simuler la démarche du photo-interprète mieux que les approches à apprentissage par l'exemple.

### **1.4.3. Hypothèse liée à la détection du changement**

Les méthodes automatiques de détection du changement sont sensibles aux corrections géométriques et radiométriques. En supposant que les données utilisées sont suffisamment bien corrigées géométriquement, l'analyse diachronique permet de relever les zones perturbées d'une scène.

## **1.5. Présentation du plan de la thèse**

Cette introduction a permis d'exposer le contexte et la problématique du travail, ainsi que les objectifs visés et les hypothèses de la recherche. Le chapitre suivant présente une revue des travaux réalisés, d'une part en matière de détection du changement et, d'autre part, en interprétation automatique à l'aide de systèmes intelligents. Cette partie est suivie de la méthodologie proposée pour cette étude. Ensuite, les différents résultats obtenus et leurs analyses sont présentés. Ce document se termine par la conclusion et les recommandations pour de futurs développements.

## 2. Revue des travaux antérieurs

### 2.1. Principes de détection et d'identification du changement

#### 2.1.1. Information ou données ?

Les données sont équivalentes à des mesures. Les images satellitaires en sont un exemple, car elles fournissent des mesures du rayonnement électromagnétique terrestre dans différentes parties du spectre. En revanche, l'information est une caractéristique que l'on peut extraire des données. Il peut s'agir de la texture ou encore des contours en imagerie. L'information est obtenue grâce à une analyse des données.

#### 2.1.2. Définition du changement

Dans le domaine de l'observation de la Terre, les auteurs s'accordent sur la définition suivante :

*un changement est une variation temporelle du spectre de la surface terrestre.*

Cette définition fait apparaître les concepts clés de la détection du changement, le temps et la surface. Selon cette définition, les changements à identifier sont des altérations naturelles de la surface. Malheureusement, l'acquisition d'une image n'est pas un processus parfait, l'instrumentation et l'atmosphère pouvant perturber le signal reçu. Ainsi, la modification de la radiométrie n'est pas uniquement due à un changement sur le terrain. En analyse d'image, les méthodes de détection du changement ne relèvent que les différences entre deux scènes. La distinction entre les changements réels et les artefacts est réalisée par la suite.

Dans le contexte de notre étude, en milieu forestier, la littérature parle plus de classes de "perturbation". Les zones perturbées se classent généralement en deux groupes, selon qu'il s'agit d'un gain ou d'une perte de biomasse. Les travaux antérieurs en détection du changement montrent qu'il est possible de détecter certaines conséquences de ces perturbations avec



des données de télédétection (Coppin et Bauer, 1996; Coppin *et al.*, 2001; Hayes et Sader, 2001; Lorena *et al.*, 2002; Civco *et al.*, 2002). Il peut s'agir de la disparition de la végétation suite à une maladie ou un feu de forêt, ou encore d'une augmentation du couvert végétal après une repousse. Les causes du changement seront déterminées par l'utilisateur à l'aide de sa connaissance sur la région. Elles peuvent être par exemple :

- un phénomène naturel, comme un feu de forêt ou encore une inondation ;
- un travail sylvicole, tel qu'une coupe ou une zone en régénération ;
- une maladie causée par un insecte ;
- la phénologie, comme la défoliation des feuillus en automne.

Dans la suite de ce chapitre, nous présentons les méthodes existantes pour mettre en relief les changements.

### 2.1.3. Procédure classique de détection du changement

La procédure classique est basée sur l'utilisation d'images satellitaires (figure 2.1). Elle est très similaire à la technique de photo-interprétation. L'interprète travaille à une plus petite échelle que la photographie et utilise l'assistance d'outils informatisés. Cette procédure, proposée par Matejek (1997) est utilisée actuellement pour la mise à jour de cartes forestières au Québec.

Pour relever les perturbations, l'interprète utilise une carte de référence et une image satellitaire récente. Les préalables pour une détection du changement sont des données comparables radiométriquement et géométriquement. La radiométrie est importante seulement dans le cas d'une utilisation d'un ensemble d'images diachroniques. Dans certains travaux, les auteurs préfèrent réaliser une calibration radiométrique des données entre elles (Tokola *et al.*, 1999). Une simple transformation des données évite l'emploi d'une méthode de correction basée

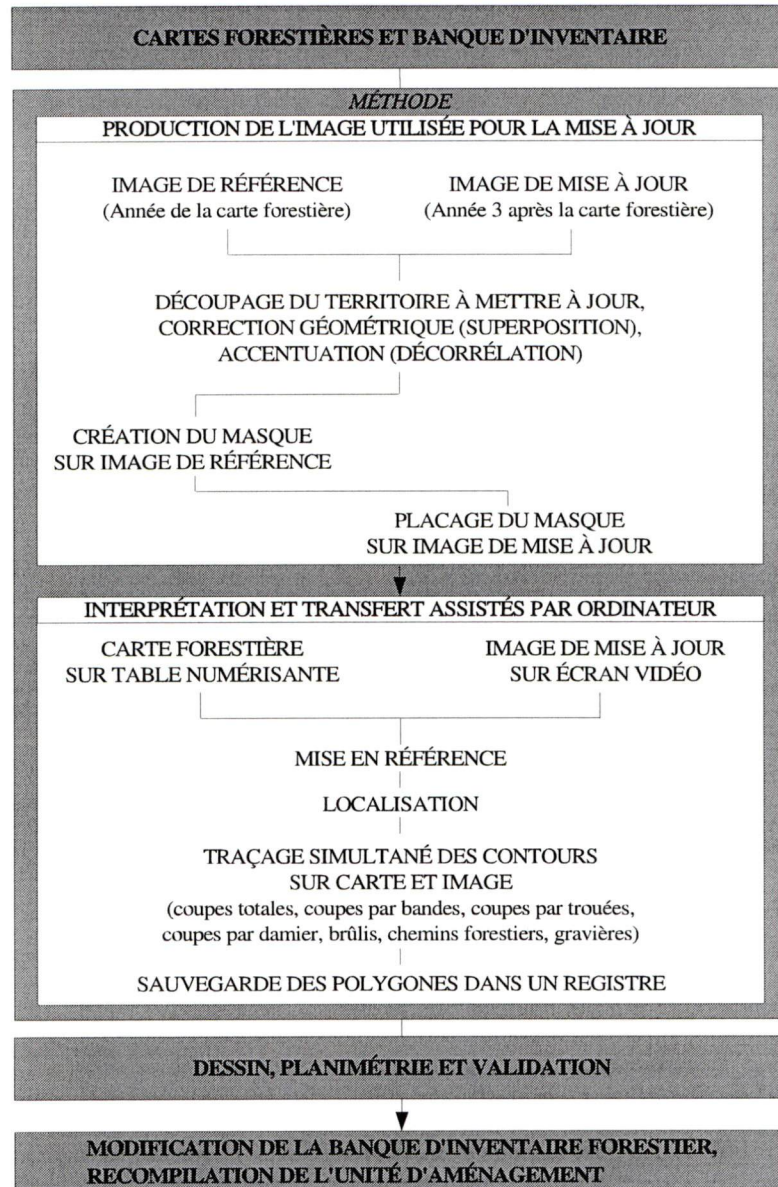


Figure 2.1: Méthode de mise à jour par image satellitaire, source : (Matejek, 1997)

sur un modèle de transfert radiatif, tel que le modèle 6S (Second Simulation of the Satellite Signal in the Solar Spectrum). Les prétraitements sont des opérations très délicates qui influencent la seconde partie de la mise à jour, à savoir l'identification du changement. Comme l'oeil d'un interprète est moins sensible aux problèmes de déformation et de calibration des images que les méthodes automatiques, l'interprétation visuelle est souvent utilisée.

Une fois les corrections réalisées, l'interprète crée un masque à partir de la carte de référence. Le masque est composé de toutes les classes non forestières, comme les zones agricoles ou urbaines. Ce masque est appliqué sur l'image récente, ce qui réduit alors le nombre de zones à analyser.

L'interprète relève à l'écran les changements sur les zones laissées apparentes par le masque. Les polygones sont finalement identifiés grâce à l'information de la carte de référence et de l'image récente rehaussée.

#### 2.1.4. L'interprétation des zones changées

Quelle soit pratiquée sur une image ou une photographie, la procédure d'interprétation est identique. Au cours de la première étape, l'interprète détermine les zones à analyser. Puis, pendant la deuxième étape, il identifie ces zones. Pour réaliser cette tâche, l'interprète utilise deux outils d'interprétation, les critères et les clés.

Les critères permettent de décrire une région selon différentes caractéristiques telles que :

- la **teinte** qui est fonction du niveau de gris dans la photographie ; dans le cas d'une image, il est possible d'utiliser les pseudo couleurs ;
- la **taille** indiquant la surface occupée par le segment ;
- l'**ombre** donnant une information sur la troisième dimension ;

- la **texture** informant sur la nature de la surface ; elle dépend de l'organisation des niveaux de gris ;
- l'**arrangement** indiquant si le segment respecte une distribution spatiale particulière ;
- l'**association** d'une information issue du **contexte** de l'objet et permettant de l'identifier.

Une clé d'interprétation est une configuration particulière de tous ces critères. L'interprète peut élaborer ces clés à partir d'échantillons relevés sur le terrain ou alors faire appel à son expérience.

Par exemple, un peuplement d'arbre peut être identifié non seulement grâce à l'aspect de sa canopée mais aussi par sa localisation sur un certain type de pente et de sol.

Le contenu de l'image n'apportant pas forcément tous les renseignements nécessaires, l'interprète utilise des documents complémentaires, comme une carte de districts écologiques ou une carte de géomorphologie. De tels documents donnent une information sur la nature et l'épaisseur du dépôt, le drainage, la pente (Arnold, 1997; Gagnon *et al.*, 1999).

L'identification dépend aussi de l'expérience de l'interprète et de sa connaissance dans le domaine (dans notre cas, il s'agit de la foresterie) ; c'est pourquoi le résultat d'une interprétation peut différer selon chaque interprète.

## 2.2. Les méthodes automatiques

Les méthodes automatiques ont été envisagées pour réduire le travail de l'interprète dans la procédure de mise à jour de carte forestière. De nombreux travaux sont basés sur l'automatisation de la détection du changement (Muchoney et Haack, 1994; Coppin et Bauer, 1996; Hame *et al.*, 1998). L'identification est moins évidente à automatiser, car le processus de vision est difficile à traduire avec les techniques utilisées jusque là. L'identification est donc



laissée dans la majeure partie des cas à un interprète. Cette section décrit les méthodes déjà utilisées en détection et identification du changement.

### 2.2.1. Les méthodes de détection du changement

Une phase importante dans la mise à jour de carte est la détection du changement. Cette étape élabore la carte des zones changées qui sont interprétées par la suite. Deux groupes sont souvent distingués ; le premier utilise les images brutes et le deuxième la classe thématique.

#### 2.2.1.1. La différence d'images

Une image de différence est obtenue par la soustraction de deux images acquises à deux dates différentes. Les images peuvent résulter du calcul d'un indice de végétation (Fraser *et al.*, 2000). L'avantage de cette méthode est l'obtention d'une image représentant l'importance du changement. Cette technique présente cependant deux inconvénients. Le premier est la nécessité que les deux images soient parfaitement corrigées d'un point de vue radiométrique. La moindre erreur dans les corrections peut être interprétée comme un changement. Le deuxième inconvénient est qu'une même variation peut indiquer des changements différents (ex : 40 -> 60, 10 -> 30).

Lorsque les perturbations sont uniquement dues à un seul phénomène, comme la perte de biomasse, cette méthode est très facile à mettre en oeuvre. Muchoney et Haack (1994) l'illustrent avec une cartographie de la défoliation causée par un insecte (lymantride spongieuse). La différence d'indice de brillance du sol ("brightness") permet de déceler avec une précision de 69 % les zones de défoliation. Cette méthode donne de meilleurs résultats que l'analyse en composantes principales ou encore l'analyse post-classification . Cette méthode permet aussi l'emploi d'un seuil pour éliminer les fausses alarmes.

### 2.2.1.2. La ratio d'image

Basée sur le même principe que la différence d'image, la méthode du ratio consiste à faire la division pixel à pixel de l'information de deux images. Dans ce cas, un ratio proche de 1 indique peu ou pas de changement. Il est possible d'utiliser le logarithme du ratio pour se rapporter à une courbe symétrique par rapport au zéro. On se retrouve dans le cas de la différence d'images. Plus on s'éloigne du zéro plus le changement est important. Comme pour la méthode précédente, un seuil de réduction des erreurs peut être mis en place. Cette technique possède les mêmes désavantages que la méthode précédente.

### 2.2.1.3. La régression linéaire

Dans ce cas, l'hypothèse est que la surface des zones changées ne soit pas trop importante. Ainsi, la majorité des pixels des deux images est corrélée. Dans ce cas, il est possible de trouver une relation linéaire entre les pixels des deux images.

L'analyse du résiduel pour chaque pixel permet de connaître si le pixel a changé dans le temps. Par ailleurs, la valeur du résiduel fournit l'importance du changement (figure 2.2).

Cette méthode présente un grand intérêt pour la réduction des problèmes liés aux corrections radiométriques et atmosphériques (Luque, 2000). En effet, même si les images ne sont pas parfaitement corrigées radiométriquement, il est possible d'appliquer la méthode. Cette approche a permis à MUNYATI (2000) de faire la cartographie des zones humides d'une région en Zambie. La régression linéaire a facilité la combinaison de données MSS et TM acquises dans des conditions totalement différentes.

Comme dans le cas des méthodes précédentes, l'élaboration d'un seuil sur le résiduel est possible pour réduire les erreurs.




Figure 2.2: Détection du changement par régression linéaire

#### 2.2.1.4. L'analyse du vecteur de changement

Cette analyse est fondée sur le fait qu'une surface évolue en fonction du temps. Le déplacement des caractéristiques de cette surface peut être représenté par un vecteur (figure 2.3).




Figure 2.3: Représentation du vecteur de changement ( $m = 2$ )

Les informations liées à la surface s'expriment dans un espace de dimension  $m$ , où  $m$  représente le nombre d'informations. L'analyse de la magnitude et de la direction du déplacement de ce vecteur permet d'identifier le changement. Le vecteur peut être calculé à partir des bandes spectrales de l'image ou d'autres paramètres, comme la texture et les indices de végétation.

En combinant cette approche avec les indices définis par Kauth et Thomas (1976), Lorena *et al.* (2002) ont montré la possibilité d'identifier certaines classes de changement telles que la déforestation et la repousse. En fait, le principe est de trouver une augmentation ou une baisse des indices de brillance du sol (brightness) et de végétation verte (greenness). Par exemple, une repousse est représentée par une diminution du premier indicateur et une augmentation du second. L'indice de brillance diminue, car l'ancien sol nu est maintenant couvert par la végétation. L'indice de végétation verte augmente simultanément. De plus, l'utilisation d'un seuil sur la magnitude du vecteur permet d'éliminer les zones erronées.

L'analyse du vecteur de changement est certainement une des méthodes les plus utilisées. Elle est malheureusement sensible aux corrections radiométriques.

#### 2.2.1.5. L'analyse en composantes principales

Plus souvent utilisée pour la réduction de la dimensionalité d'un problème, l'analyse en composantes principales (ACP) apporte une solution intéressante à la détection du changement. L'ACP permet d'exprimer un système de dimension  $n$  dans un espace de plus petite dimension. La réduction de l'espace est possible, car les informations peuvent être corrélées entre elles. Dans ce cas, il n'est plus nécessaire de conserver toutes les informations pour représenter le problème.



Si l'on utilise des images diachroniques d'une même zone, il apparaît que la corrélation est faible sur les zones changées et respectivement forte sur les zones inchangées. Les zones changées se retrouvent alors dans certaines composantes. Muchoney et Haack (1994) ont trouvé notamment que la première composante représente le changement dans la brillance du sol, tandis que la deuxième composante indique un changement dans la végétation verte. La troisième composante est, quant à elle, dépendante de la défoliation ou d'un changement dans le proche infrarouge .

#### 2.2.1.6. L'analyse post-classification (APC)

Cette technique utilise une carte thématique de référence provenant d'un système d'information géographique (SIG) ou d'un outil de classification. La carte des changements résulte de la comparaison de cette carte de référence avec un résultat de classification.

L'avantage majeur est la réduction du problème de calibration radiométrique entre les données. En effet, les images n'ont pas besoin d'être parfaitement corrigées puisque c'est la classe thématique qui est utilisée.

L'inconvénient majeur est que la qualité du résultat final dépend de la précision des différentes procédures d'extraction de l'information cartographique. Comme les deux cartes thématiques sont obtenues selon des procédures différentes, des changements peuvent apparaître simplement à cause d'erreurs commises dans chacune d'elles. On parle dans ce cas d'erreurs multiplicatives. L'outil de classification peut notamment commettre des erreurs en raison de la confusion spectrale des classes.

Une des faiblesses de l'APC est qu'elle ne permet pas la mise en place d'un seuil pour éliminer les fausses alarmes.

### 2.2.1.7. L'analyse par corrélation croisée

Cette technique utilise un résultat de classification ou une ancienne carte thématique. L'idée s'appuie sur le calcul de  $Z$  décrit par la relation 2.1.

$$Z_{jk} = \sum_{i=1}^{N_b} \left( \frac{r_{ijk} - \mu_{ic_{jk}}}{\sigma_{ic_{jk}}} \right)^2 \quad (2.1)$$

où,  $Z_{jk}$  : la valeur du pixel d'indice (j,k)

$i$  : la bande considérée

$N_b$  : le nombre de bandes

$c_{jk}$  : la classe thématique (ancienne classe)

$r_{ijk}$  : la réflectance du pixel

$\mu_{ic}$  : la moyenne de la classe  $c$  dans la bande  $i$

$\sigma_{ic}$  : l'écart-type de la classe  $c$  dans la bande  $i$

Si le pixel n'a pas changé de classe dans le temps, la valeur de  $Z$  est faible. Les caractéristiques du pixel sont proches de la classe à laquelle il appartenait auparavant. Par contre si le pixel a subi une perturbation, la valeur de  $Z$  est importante. En considérant que le pixel peut être décrit selon un vecteur  $r_{ijk}$ ,  $Z$  est similaire à la distance normalisée de ce vecteur par rapport au vecteur décrivant la classe  $c_{jk}$ .

L'avantage de cette approche est de réduire les effets radiométriques mais aussi les problèmes liés à la phénologie. L'image obtenue de la valeur  $Z$  permet aussi de mettre en place un seuil. Civco *et al.* (2002) ont utilisé cette méthode pour établir l'expansion de zones urbaines. Dans ce cas, les changements importants sont relevés (végétation -> zone urbaine) et les faibles variations dans la végétation ne sont pas considérées.

### 2.2.2. L'identification automatique

L'utilisateur a la possibilité d'utiliser plusieurs méthodes pour identifier les changements. Actuellement, les méthodes complètement automatiques n'existent pas. L'utilisateur doit encore introduire certains paramètres.

#### 2.2.2.1. Le seuillage

De nombreuses méthodes, parmi celles présentées précédemment, favorisent l'emploi d'un seuil. En effet, ce type de méthodes donne un résultat sous forme d'une image où la valeur du pixel représente l'importance du changement. L'utilisateur peut alors établir un seuil sur la valeur des pixels afin de séparer le bruit des changements réels. Cette approche peut être intéressante lorsque la scène présente un seul type de perturbation. Le résultat de cette identification dépend beaucoup du seuil choisi. Certains travaux proposent de déterminer automatiquement un seuil (Mas, 1999). La procédure proposée est d'établir un seuil de départ à partir de la distribution des niveaux de gris, puis de le modifier à chaque itération. Le résultat obtenu avec le seuil est évalué sur des zones connues avec le coefficient  $Kappa$ . Si ce nouveau seuil permet d'obtenir une meilleure valeur de  $Kappa$ , alors on passe à l'itération suivante, sinon on arrête. Toute cette procédure est automatique.

Le calcul du seuil étant basé sur les statistiques d'une courbe gaussienne, le seuillage automatique nécessite une distribution normale de l'information. Cette approche ne peut donc pas être utilisée pour les méthodes de détection ne respectant pas cette contrainte.

#### 2.2.2.2. La méthode du tableau à double entrée (cross-tabulation)

Cette approche peut être envisagée dans le cas d'analyse post-classification (APC). Elle est basée sur le même principe que la matrice de confusion. Le tableau est composé des classes originales et des classes actuelles. Les valeurs dans la diagonale du tableau sont les pixels qui n'ont pas changé de classe, alors que les autres valeurs sont considérées comme un

changement. Le type de changement est identifié grâce à la classe d'origine et de destination. En plus de l'identification, il est possible d'estimer les superficies atteintes par le phénomène.

Par ailleurs, cette méthode permet l'élimination de certaines transitions peu vraisemblables, qui peuvent provenir d'erreurs dans la procédure. Civco *et al.* (2002) ont défini les transitions possibles dans une région urbaine et ont pu estimer l'expansion d'une ville.

### 2.2.2.3. La classification

L'identification peut être réalisée grâce à une méthode de classification dirigée. L'approche peut utiliser une méthode classique, comme le maximum de vraisemblance. Si l'ensemble de données fournit des images à plusieurs dates, il est intéressant d'analyser l'évolution du spectre de chaque classe. Il est alors possible de mettre en place des techniques plus élaborées, comme la fusion de données temporelles. Bruzzone *et al* (1999) proposent une approche à l'aide de réseaux de neurone pour combiner des données à différente date. Cette approche permet de combiner les données d'un même capteur à différente date, mais aussi les données de capteurs différents.

## 2.3. Limites des méthodes automatiques

La détection du changement exige des données parfaitement corrigées. En réalité, les corrections ne sont jamais exactes et des erreurs peuvent résulter de ces opérations. Mise à part les problèmes liés à la préparation des données, d'autres problèmes peuvent affecter la procédure, tels que le type des données et les algorithmes utilisés. Dans la suite de cette section, nous nous intéressons à présenter les problèmes les plus fréquemment rencontrés.


### 2.3.1. La nature des données

Un des problèmes majeurs provient du type de donnée utilisé. Dans le cas des projets de détection du changement utilisant les données à moyenne ou à très haute résolution spa-



tiale, les auteurs font face à des problèmes complètement différents (Coppin et Bauer, 1996; Metternicht, 1999). Les données dont la limite de résolution est de 20 à 30 m présentent de nombreux pixels mixtes. Ceci rend difficile la définition de classes pures et peut entraîner des problèmes dans la suite des traitements, notamment lors de la classification. En revanche, les images à très haute résolution spatiale (limite de résolution de 1 m) présentent une importante variabilité locale des niveaux de gris. À cette échelle, l'identification visuelle des segments présents dans l'image est efficace. Les méthodes automatiques actuelles d'analyse d'image ne sont pas encore adaptées à ce nouveau type de données.

Des approches doivent être développées pour chaque type de capteur, puisque l'aspect de l'objet à identifier dépend fortement de la résolution spatiale du capteur. La figure 2.4 montre une même région observée par les capteurs TM de Landsat et Ikonos.



**Figure 2.4:** La même région vue par Ikonos et Landsat TM

La route dans cette scène ne peut donc pas être extraite de la même manière.

### 2.3.2. Les méthodes de classification

L'APC nécessite l'utilisation d'un résultat de classification. Plusieurs limitations apparaissent dans les outils de classification. Premièrement, les méthodes de classification se limitent uniquement à l'utilisation de l'information spectrale. Effectivement, l'emploi d'une seule source d'information ne permet pas forcément d'identifier les classes désirées. L'ajout d'une donnée complémentaire à l'image permet alors d'améliorer les résultats des outils de classification. Il est possible d'introduire l'information texturale, mais cela nécessite des méthodes particulières (Franklin et Peddle, 1989; Kushwaha *et al.*, 1994). Des approches basées sur la fusion de données existent en analyse d'images, mais elles ne sont pas encore intégrées dans les procédures de détection du changement (Allard, 2001).

Deuxièmement, les méthodes disponibles ne conviennent pas à la génération des nouveaux capteurs, tels que le radar ou la très haute résolution spatiale. La plupart des outils utilisés ont été élaborés pour des résolutions de l'ordre de 20 ou 30 m. Il devient nécessaire de développer de nouveaux outils pour ce type de capteur.

### 2.3.3. L'identification automatique

Les méthodes d'identification automatique du changement sont étudiées depuis peu (Mas, 1999). Les travaux de recherche en détection du changement se sont plutôt focalisés sur l'amélioration des prétraitements, ou encore sur les algorithmes de détection (Coppin et Bauer, 1996). Ainsi, les travaux proposent uniquement des méthodes de seuillage automatique comme alternative à l'identification visuelle. Pourtant, de nombreux travaux de recherche existent en analyse d'image, notamment dans la reconnaissance automatique de forme (Foresti et Gentili, 2000; Müller et Eickerler, 2001). Quelques approches ont été proposées pour la télédétection (Walter, 2004). McKeown *et al.* (1985) ont développé une approche pour la reconnaissance de bâtiments sur les photographies aériennes. La méthode est assez complexe, car elle combine une modélisation 3D de la scène et un système à base de règles pour identifier le type de bâtiment. Une telle approche pourrait avoir un intérêt en détec-

tion du changement, car les perturbations sur le terrain seraient mesurables selon les trois dimensions. Malheureusement, les solutions proposées en reconnaissance de forme sont assez difficiles à mettre en place et demeurent souvent à l'état de prototype.

## 2.4. Récents développements

Les derniers développements en détection du changement se classent selon trois axes principaux :

- l'approche floue ;
- le changement d'échelle ;
- la nouvelle information.

Le premier groupe répond à la difficulté d'identifier automatiquement les différentes classes de perturbation. Le seuillage automatique se limite à la distinction entre un changement réel et un bruit. Cependant, si l'utilisateur désire établir plusieurs classes de changement, cette approche n'est plus possible. C'est pourquoi Metternicht (1999) propose une solution faisant appel à la logique floue. Cette théorie utilise des fonctions floues qui représentent le degré d'appartenance d'un pixel à une classe. Cette approche a permis à l'auteur de relever les changements sur des photographies aériennes. Les changements sont classés selon une échelle d'importance (ex : pas de changement, changement faible, fort, très fort, etc...). Cette méthode apporte une solution intéressante dans le cas des images à très haute résolution.

Le deuxième axe concerne la combinaison d'informations à différentes résolutions. La limite de résolution des capteurs de télédétection s'améliore et permet d'obtenir des données spatialement de plus en plus précises. L'analyse des changements d'une région du globe peut s'effectuer sur plusieurs décennies. Cela nécessite parfois l'utilisation de capteurs avec des résolutions spatiales différentes. En général, les auteurs utilisent une méthode d'interpola-

tion spatiale pour mettre toutes les données à la même échelle. Depuis quelques années, le problème de l'échelle en télédétection est abordé grâce à la transformée en ondelettes. Cette approche est apparue notamment dans la classification (Fau *et al.*, 1994) et le filtrage (Foucher *et al.*, 2001). Plus récemment, Dayraie (2003) a utilisé cette approche dans la détection du changement à l'aide des images Landsat TM5 et ASTER. Son travail a montré la possibilité de combiner des données d'anciens et de nouveaux capteurs.

Le dernier groupe tente d'utiliser les nouveaux capteurs. Actuellement, peu de travaux utilisent les images radar. En effet, le radar peut être une alternative au domaine optique. Huyck *et al.* (2002) ont montré le potentiel de l'imagerie radar suite au tremblement de terre en Turquie de 1999. Dans le cas d'un tremblement de terre, les structures telles que les bâtiments et les ponts, peuvent être très détruits. Le signal radar étant très sensible à la géométrie de la surface, une analyse du signal avant et après le sinistre peut établir si la structure a subi d'importants changements. Le radar permet une acquisition en tout temps, ce qui lui confère un intérêt pour les régions tropicales, comme l'Amazonie. De plus, Radarsat international propose une procédure accélérée pour la commande d'images dans les situations urgentes. En revanche, les données radar demandant des traitements particuliers et très différents des données optiques, peu de travaux tentent de les utiliser. De nouvelles approches de détection du changement sont encore à développer pour ce type d'images.



## **2.5. L'interprétation de données de télédétection à l'aide de systèmes de décision**

Dans le chapitre précédent, les systèmes intelligents ont été présentés comme une solution possible pour le développement de nouvelles méthodes d'identification du changement. Il existe de nombreuses applications de ces systèmes en télédétection. Une revue de travaux sur les systèmes experts en télédétection peut être trouvée dans (Tsatsoulis, 1993). De même, des applications des réseaux de neurones sont présentées dans (Atkinson et Tatnall, 1997). Quant à Friedl et Brodley (1997), ils présentent les arbres de décision en télédétection.

Dans cette partie, nous détaillons uniquement les systèmes de décision dans le cadre de l'interprétation.

### **2.5.1. Définitions dans le domaine de l'intelligence artificielle**

La recherche en IA existe depuis le milieu des années 50. Cependant, la définition d'un système intelligent est encore très vague (Russell et Norvig, 2003). En général, un système est considéré intelligent si ses capacités sont semblables à celles d'un être humain. En l'occurrence, il doit être capable de percevoir son environnement, d'acquérir de nouvelles connaissances et de raisonner.

Les systèmes à base de règles, les réseaux de neurones et les arbres de décision sont les systèmes intelligents les plus utilisés. Ils sont souvent appelés systèmes de décision ou d'aide à la décision. En fournissant une analyse rapide des informations, ils facilitent la prise de décision par un gestionnaire. Dans la suite du chapitre, nous utiliserons le terme systèmes d'aide à la décision pour parler des systèmes intelligents.

Le terme "base de règles" est équivalent à la base de connaissances du système. En effet, la connaissance est introduite dans le système sous la forme de règles, c'est pourquoi les deux termes peuvent apparaître dans le texte.

### 2.5.2. Revue des travaux en télédétection

Les systèmes d'aide à la décision apparaissent dans diverses applications en télédétection. Les systèmes à base de règles peuvent apporter une assistance à l'utilisateur dans différentes tâches. Une base de connaissances contient alors l'expérience d'un expert pour une tâche bien précise. Rousseau *et al.* (2002) ont élaboré un système à base de règles pour aider un usager dans le choix des données pour un projet particulier. MYCIN est le meilleur exemple en ce qui concerne le développement de système d'aide. Développé dans les années 70 par l'université de Stanford, il assiste l'utilisateur dans l'identification de bactéries causant une infection sanguine. Le système réalise un diagnostic avant même que les résultats de la culture bactériologique soient connus.

Les systèmes d'aide à la décision permettent aussi l'intégration de données de divers types. Les applications basées sur l'utilisation d'un système d'information géographique (SIG) ou encore les approches par fusion d'informations bénéficient grandement de ces systèmes. Ainsi, les informations issues de l'image satellite combinées à celles d'un SIG peuvent être analysées. Les travaux de Loh *et al.* (1994) proposent un système à base de règles pour analyser l'information d'un SIG. Cette analyse aide le forestier dans la gestion de son territoire. Dans ce cas, le système établit les futurs travaux sylvicoles. Dans le contexte de la fusion de capteur, Clément *et al.* (1993) ont élaboré des *spécialistes* pour identifier des objets sur des images optiques et radar. Chaque spécialiste se concentre sur la reconnaissance d'un élément particulier, tel qu'une rivière, une habitation ou encore un pont. Des spécialistes d'un niveau supérieur vérifient si l'information provenant des "sous-spécialistes" est en accord. Cette structure est similaire à une architecture multi-agents, où chaque module (agent) est

adapté à un problème particulier. En adaptant la connaissance des spécialistes à différents types d'images, cette approche apporte une alternative intelligente à la fusion de capteurs.

Le domaine le plus développé est certainement l'interprétation ou la classification de données de télédétection. L'interprétation peut être assimilée plus ou moins à une classification. En général, l'interprétation regroupe conjointement la classification et l'intégration de données. Ces domaines de l'analyse d'images sont bien distincts dans les travaux de recherche, mais le processus d'interprétation les combine. L'association de ces deux axes dans un même système ne justifie pas forcément l'utilisation d'un système d'aide à la décision. En effet, parfois de simples méthodes statistiques permettent d'obtenir des résultats satisfaisants. On peut notamment citer la classification par le maximum de vraisemblance ou encore la distance minimale. Cependant, l'interprétation fait appel à la notion d'expérience et de connaissances que, seuls, ces systèmes peuvent mettre en place.

Une constatation émane de la littérature : la manière d'utiliser les méthodes issues de l'IA a changé. Les premiers travaux ont tenté de résoudre des problèmes trop complexes avec les systèmes d'aide à la décision et peu de résultats probants ont été obtenus. Actuellement, les solutions proposées sont plutôt l'utilisation d'un système plus simple désigné pour une tâche plus précise. En détection du changement, Goldberg *et al.* (1985) ont imaginé un système expert pour la mise à jour de carte. Le système était découpé en trois niveaux, l'intégration et l'analyse des données, l'extraction de paramètres environnementaux et la prédiction à l'aide de modèles. Chaque niveau nécessite un système expert, appelé dans ce cas, spécialiste. L'architecture permet ainsi de distribuer la connaissance. Malheureusement un tel système n'a pas été évalué et la complexité du système laisse supposer qu'il est difficile d'harmoniser tous les spécialistes.



Dans des travaux plus récents, l'utilisation d'un système à base de règles a été envisagée soit comme complément d'une méthode conventionnelle, ou comme outil de classification. La première utilisation considère les méthodes intelligentes comme un outil de correction d'une méthode déjà existante. Cette approche est semblable aux méthodes relaxationnistes (ICM). Le principe est donc de vérifier si le résultat proposé par la méthode conventionnelle est conforme à certaines conditions contenues dans une base de règles (Liu et Zhou, 2004).

La deuxième utilisation consiste à offrir une alternative aux méthodes traditionnelles d'analyse d'images. Un des problèmes rencontrés par les méthodes traditionnelles est l'intégration de données diverses. De nombreux travaux dans la classification d'images LANDSAT nous montrent que les systèmes intelligents peuvent intégrer aussi bien de l'information numérique que nominale. La plupart des systèmes dans la littérature intègrent l'information spectrale et contextuelle (Ton *et al.*, 1991), voir texturale (Moller-Jensen, 1990) ou encore spécifique au domaine (Stefanov *et al.*, 2001). Une approche orientée objet peut être associée avec ces systèmes, ce qui permet d'intégrer des informations, comme la géométrie (Hartog *et al.*, 1996; Sester, 2000). Les systèmes intelligents obtiennent, pour certaines applications, des résultats supérieurs aux méthodes conventionnelles. Les travaux de Huang et Jensen (1997) illustrent la possibilité de combiner dans un système expert l'information spectrale, texturale et des paramètres issus d'un modèle numérique d'altitude. Le système à base de règles permettait d'obtenir des résultats supérieurs à une classification par le maximum de vraisemblance ou encore Isodata.

Par ailleurs, l'avantage des systèmes d'aide à la décision est l'utilisation d'une connaissance relative au domaine d'application. En général, cette information provient de la théorie ou de l'expérience d'un expert. Elle est non spatiale et difficile à intégrer dans les méthodes conventionnelles. La cartographie très précise du sol en milieu forestier n'est pas possible avec seulement une image LANDSAT. Skidmore *et al.* (1996) l'ont montré en élaborant une



base de règles provenant de la géomorphologie, notamment sur les relations entre l'occupation du sol et la topographie ou le dépôt de surface. Un système muni de cette connaissance a permis d'obtenir des résultats aussi précis que ceux d'un interprète.

Lorsqu'il est difficile de formuler notre connaissance pour une application, l'extraction de celle-ci est réalisée à partir des données. Les réseaux de neurones et les arbres de décision sont déjà utilisés en télédétection, notamment en classification (Friedl et Brodley, 1997; Rollet *et al.*, 1998). Les réseaux de neurones permettent d'établir une relation entre des paramètres d'entrée (ex : les attributs d'un objet) et une classe thématique. Cette relation entre les entrées et les sorties du réseau est par contre difficile à expliquer. L'arbre de décision fournit une synthèse de l'information contenue dans un ensemble d'observations. Dans ce cas, les relations trouvées entre les entrées et sorties du système sont plus facilement compréhensibles. La méthode ID3 munie de l'extension C4.5 permet notamment l'analyse de données incomplètes, c'est-à-dire avec une information manquante (Breiman *et al.*, 1984; Quinlan, 1986; Friedl et Brodley, 1997). De plus, elle intègre aussi bien l'information discrète que continue. Cette méthode est apparue assez récemment en télédétection. Elle a permis d'analyser l'information d'un SIG et d'établir une identification des éléments du paysage urbain (Sester, 2000).

Les exemples ci-dessus semblent présenter les systèmes d'aide à la décision comme un outil idéal. Malheureusement, ils présentent de nombreuses limitations. Les systèmes par apprentissage dépendent énormément des exemples choisis. Un mauvais choix peut entraîner un système mal adapté au problème. Identiquement, les systèmes à base de règles nécessitent des règles efficaces pour le problème. Ces règles sont quelques fois difficiles à exprimer dans la base. Ces problèmes seront discutés dans la suite du document.

### 2.5.3. Principe général de l'interprétation automatique

Pour parvenir à une identification des zones présentes dans une image, une suite d'opérations est nécessaire (figure 2.5). Premièrement, la segmentation permet de regrouper les pixels de l'image en entités plus importantes. Ce regroupement s'effectue selon des critères statistiques, tels que l'homogénéité des niveaux de gris. La segmentation est nécessaire pour mettre en place une approche par région. Les segments peuvent être décrits selon une série d'attributs numériques, comme la géométrie ou la texture. À la fin de cette étape, l'image est représentée par un ensemble de segments associés de leurs attributs.

À ce niveau, un outil de classification ou un système de décision analyse les attributs de la région et peut définir une classe. Selon la nature des attributs de la région, certaines méthodes seront préférées. L'utilisation de certaines d'entre elles peut requérir une distribution normale, comme le maximum de vraisemblance. En revanche, les systèmes de décision intègrent tous les types d'information, c'est pourquoi ils sont souvent envisagés lors de la résolution de problème dont on a aucun *a priori* sur les données.

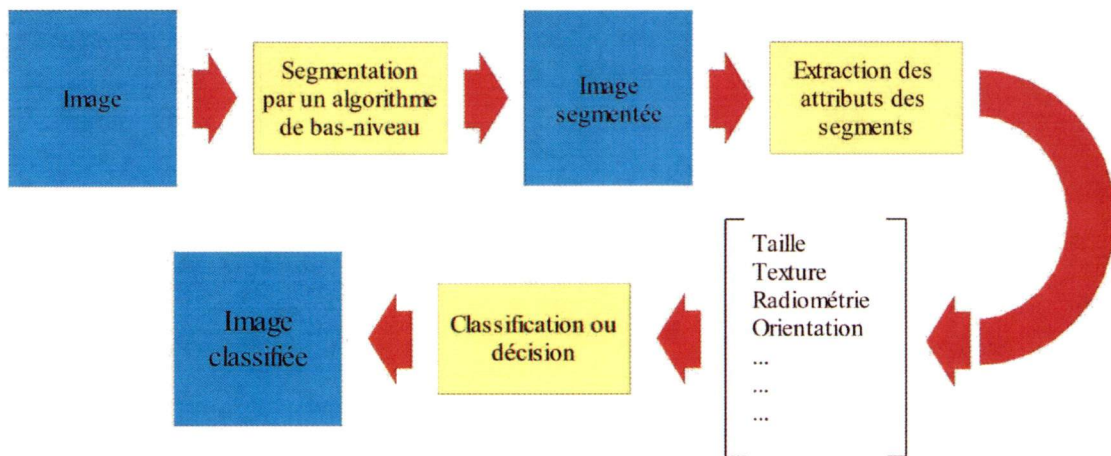


Figure 2.5: Processus de reconnaissance automatique

L'interprétation de données s'apparente fortement à une classification, mais elle fait appel à des connaissances *a priori* dans le domaine de l'application. Peu de méthodes conventionnelles en analyse d'image permettent d'intégrer ces connaissances, par contre les systèmes d'aide à la décision offrent cette possibilité.

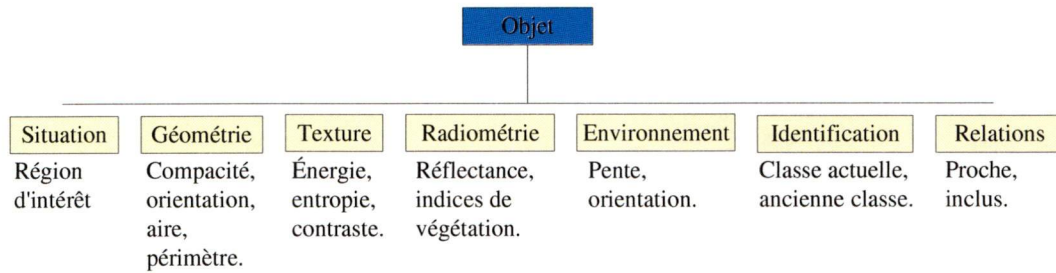
Si une méthode intelligente s'impose, alors son choix dépend souvent des connaissances *a priori* sur l'application. Deux groupes sont à distinguer, les systèmes à base de connaissances et les méthodes à apprentissage par l'exemple. Les différents systèmes sont expliqués plus loin dans le chapitre.

#### 2.5.4. L'approche orientée objet

L'expression d'approche orientée objet est un concept de programmation informatique. Selon cette approche, un logiciel est composé d'une collection d'objets. Chaque objet a sa propre structure et ses propres méthodes. En analyse d'image, l'approche orientée objet est équivalente à une analyse par région (ou par champ) selon l'application (Lloyd *et al.*, 2004; Mueller *et al.*, 2004). Dans ce cas, cette approche s'oppose à l'analyse pixel par pixel de l'image.

Plusieurs constatations amènent à penser que l'approche orientée objet est plus adaptée à l'interprétation de données qu'une approche par pixel. D'abord, en photo- ou image- interprétation, l'analyse s'effectue au niveau d'une région. L'interprète utilise de nombreux critères, dont la géométrie, que seul un segment permet d'obtenir. La figure 2.6 donne la plupart des attributs d'une région.

D'un autre côté, une scène de la vie réelle est plutôt composée d'objets en interaction. L'approche orientée objet, contrairement à celle par pixel, permet de mettre en oeuvre des relations plus complexes entre les éléments. Sester (2000) utilise entre autres la perpendicu-



**Figure 2.6: L'objet et ses attributs**

larité et le parallélisme pour identifier des éléments dans le milieu urbain. De telles relations sont impossibles à considérer dans une approche par pixel.

D'un point de vue technique, l'approche orientée objet permet aussi de réduire le temps de calcul. En effet, le nombre de segments à analyser est plus faible que le nombre de pixels.

### 2.5.5. Le choix de l'apprentissage

Afin de former le système à l'application, il est nécessaire de passer par une phase d'apprentissage. Deux approches sont possibles pour obtenir la connaissance. La première est l'extraction automatique de la connaissance à partir d'observations et la deuxième est dirigée par l'utilisateur. Les réseaux de neurones et les arbres de décision utilisent la première approche aussi appelée, l'apprentissage par l'exemple, tandis que les systèmes à base de règles obtiennent leurs connaissances généralement d'un expert humain.

L'apprentissage par l'exemple peut être préféré à la deuxième approche :

- si le domaine d'application ne permet pas d'élaborer explicitement des règles entre les attributs des segments et les thèmes recherchés ;
- si le problème possède suffisamment d'exemples représentatifs de tous les cas particuliers.



L'inconvénient majeur de l'apprentissage par l'exemple est le choix de l'ensemble de données pour l'entraînement (Foody, 1997). Si les patrons d'apprentissage représentent trop de cas spécifiques, le système s'applique mal au problème en général (sur-apprentissage). Si les patrons ne représentent pas tous les cas de figures, alors le système peut se trouver dans une indécision (sous-apprentissage). Dans les deux cas, il est essentiel d'effectuer un nouvel apprentissage en corrigeant l'ensemble d'apprentissage.

L'apprentissage dirigé par un expert permet de regrouper la connaissance sous forme de règles dans une base. Dans le cas d'une indétermination du système, l'ajout d'une nouvelle règle permettra de corriger cette faille. Contrairement à la première approche, la connaissance est explicite. La clarté de la base permet une pérennité de la connaissance et de l'expérience.

Huang et Jensen (1997) ont utilisé un apprentissage par l'exemple pour élaborer les règles d'un système à base de connaissances. L'apprentissage, basé sur la méthode ID3 "Iterative Dichotomizer (version) 3" (Quinlan, 1986), permet d'élaborer un arbre décisionnel pour la classification des données. L'arbre peut alors être retranscrit sous forme de règles dans une base de connaissances d'un système expert. Cette technique permet ainsi de mettre en place un système à base de règles sans effectuer la traduction de la connaissance de l'application en règles. La gestion de la connaissance est aussi simplifiée puisque l'utilisateur bénéficie des avantages de la base de règles.

L'apprentissage est une phase très importante pour les systèmes de décision puisqu'il conditionne le système pour l'application. En général, lorsqu'il est pratiqué de manière automatique, il est vérifié à l'aide d'un ensemble de données de validation. Dans le cas de la reconnaissance d'objets, l'utilisateur identifie des régions (d'apprentissage) dans la scène. L'ensemble est alors partagé en deux, une partie pour l'entraînement et l'autre pour la validation. Cette approche rappelle la classification dirigée.

### 2.5.6. Quelques systèmes de décision

Dans cette partie, nous présentons les systèmes de décision les plus répandus dans la littérature.

#### 2.5.6.1. Les systèmes à base de règles

La théorie des systèmes à base de règles a été développée durant les années 70. Ils sont basés sur le fait que la connaissance doit être dissociée du mécanisme de raisonnement. Ce type de système permet d'exprimer explicitement la connaissance *a priori* sous la forme de règles. Il est choisi lorsque la connaissance doit être conservée explicitement. En effet, un problème souvent rencontré est la perte de l'expérience après le départ d'un expert. La base de connaissances permet donc de regrouper la connaissance et assure la pérennisation des compétences.

En guise d'exemple, nous présentons un système à base de règles inspiré du système expert JESS (Java Expert System Shell) (Friedman-Hill, 2003).

##### a) Architecture générale

La majorité des systèmes à base de connaissances respecte l'architecture de la figure 2.7. Le système est alors composé de trois modules distincts :

- d'un moteur d'inférences qui se charge d'activer les règles selon les faits présents ;
- d'une base de règles, contenant l'expérience et la connaissance de l'expert ;
- d'une base de faits, considérée comme la mémoire de travail.

La base de connaissances regroupe la base de règles et la base de faits. Le nombre de règles est déterminé au départ de l'analyse, tandis que le nombre de faits évolue en fonction du temps. Il est aussi possible d'autoriser l'ajout dynamique de règles et de modifier la base au

cours du traitement.

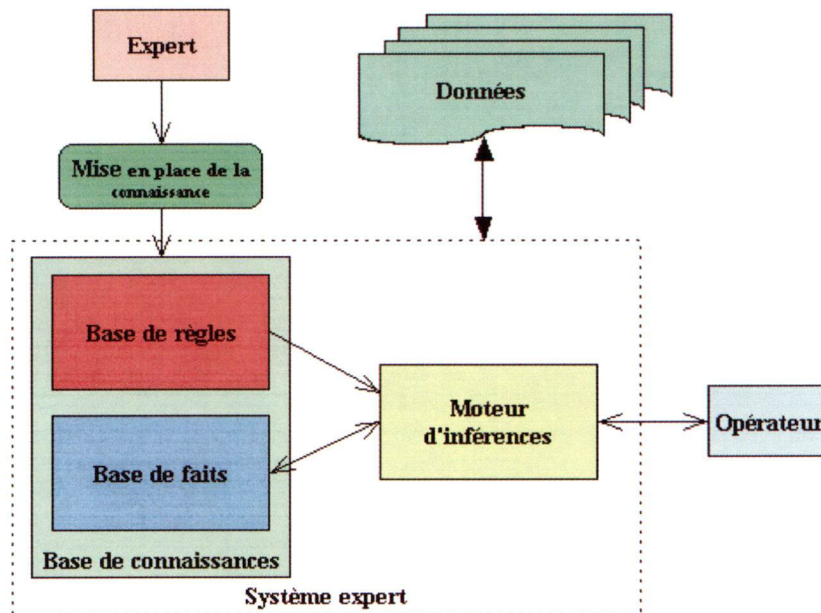


Figure 2.7: Architecture générale

#### b) Le moteur d'inférences

Le moteur d'inférences détermine le mécanisme de raisonnement du système. Il en existe trois :

- le chaînage avant ;
- le chaînage arrière ;
- le chaînage mixte.

Le chaînage avant est très utilisé dans les systèmes experts actuels. Le principe est de prendre l'ensemble des règles et des faits initiaux et de déduire des faits nouveaux grâce à l'activation

de certaines règles. Ce mécanisme illustre le processus de déduction.

Le chaînage arrière est, quant à lui, plus complexe à mettre en oeuvre. Le principe est de répondre à une question, comme "le segment est-il un lac ?". Ensuite il faut établir la liste des règles qui déduisent cela. Finalement, il faut vérifier l'état des faits qui permettent d'activer ces règles. Normalement le nombre de règles à vérifier et le nombre de faits en mémoire sont plus faibles qu'avec la première approche. Ce processus fonctionne par induction.

Le chaînage mixte est une combinaison des deux modes. Il est alors possible de raisonner à partir des faits de la base et poser des questions à l'utilisateur afin de compléter ceux-ci. L'association des deux principes permet de conduire à la déduction.

L'exemple suivant illustre les différents principes de fonctionnement. Prenons la base de règles suivantes permettant de déterminer un animal :

```
s'il a des plumes et il pond des oeufs => c'est un oiseau
s'il a des écailles et il vit sur la terre et il pond des oeufs => c'est un
reptile
s'il a des écailles et il vit dans l'eau et il pond des oeufs => c'est un poisson
s'il a de la fourrure et il boit du lait => c'est un mammifère
s'il est vivipare et il boit du lait => c'est un mammifère
s'il est un oiseau et il ne vole pas et il nage => c'est un pingouin
s'il est un oiseau et il ne vole pas et il est gros => c'est une autruche
s'il est un mammifère et il vit dans l'eau et il est gros => c'est une baleine
s'il est un poisson et il est gros => c'est un requin
s'il est un reptile et il n'a pas de pattes => c'est un serpent
```

(exemple traduit de l'anglais du cours d'IA (Northrop, 2005))



Selon le chaînage avant, si la base de fait contient les faits "a des écailles", "vit dans l'eau" et "pond des oeufs", le système peut déduire que l'animal est un poisson, mais la base ne contient pas assez de faits pour conclure que c'est un requin.

Dans le cas du chaînage arrière, si l'objectif est de savoir si l'animal est un requin, alors il faudra vérifier que 1) l'animal est un poisson et 2) qu'il est gros. Il est nécessaire de trouver les règles qui permettent de conduire à ces deux déductions. Pour cela, on remarque qu'il faut vérifier la troisième règle, et en particulier, l'état des faits "a des écailles", "vit dans l'eau" et "pond des oeufs". Dans notre cas, ces trois faits existent et sont vérifiés, par contre on ne sait pas si l'animal est gros. Le système va donc obtenir cette information de l'utilisateur.

Le chaînage avant est généralement utilisé en interprétation de données, car le processus de déduction correspond plus à la manière de procéder dans ce type de problème. En effet, l'interprète réalise des déductions à partir de faits constatés.

#### c) La base de connaissances

- la représentation de la connaissance

La base de connaissances est composée de deux grandes parties (figure 2.7). La première est l'ensemble des faits et la seconde concerne les règles. Le lien entre les deux parties est réalisé par le moteur d'inférences, qui active certaines règles en fonction des faits en mémoire.

- les faits

La base de faits est constituée des faits initiaux et des faits déduits. Les premiers proviennent des données en entrée et les seconds des déductions réalisées par le système. Les faits peuvent

être booléens, symboliques ou réels.

L'avantage d'un système à base de règles est l'utilisation de faits symboliques. Ces faits sont généralement des termes spécifiques au domaine d'application. Si l'on reprend l'exemple précédent de la base de règles, tous les faits sont exprimés dans des termes explicites, comme "a des plumes" ou "boit du lait". Ceci permet alors d'élaborer des règles non plus sur une valeur numérique mais bien sur une représentation symbolique de l'attribut. La représentation symbolique est plus proche du langage humain.

- les règles

La base de connaissances est composée de règles très simples du type :

si fait(s) ou condition(s) réalisé(s) alors action.

La règle correspond au principe d'une réponse conditionnée. L'expert attribue un facteur de certitude à chaque règle (variant de -1 à 1). Ce degré reflète la confiance que l'expert accorde à la règle. Un facteur égal à -1 signifie qu'il est impossible d'atteindre la déduction avec les faits considérés. Inversement, un facteur de 1 signifie que les faits considérés conduisent toujours à la déduction. On retrouve ce paramètre en fusion d'informations lorsqu'on associe un paramètre d'incertitude à une source.

- organisation des règles

Cette base doit être structurée, car si le nombre de règles est important, des difficultés de gestion peuvent survenir. Le classement des règles selon certains critères est primordial. La structure de la base doit permettre la vérification et l'ajout des règles. Cette condition garantit la cohérence et l'évolution de la base de connaissance en évitant la redondance de règles.

d) La prise de décision

Le processus de raisonnement se conclut par une prise de décision. Dans le cas du chaînage avant, la décision est prise lorsque aucune règle ne peut être activée. Par contre, le mécanisme de chaînage arrière se termine lorsque l'objectif à prouver est confirmé, infirmé ou indéterminé.

e) Avantages et inconvénients

Les systèmes à base de règles permettent une gestion de la connaissance plus facile que les autres systèmes. Cette connaissance peut facilement être mise à jour au fil du temps. Par contre, ils présentent plusieurs limitations majeures.

- Le temps

Le temps de raisonnement peut être parfois long. En fait, ce temps dépend du nombre de règles et de faits de la base de connaissances. Il dépend fortement de la complexité des règles de la base. La complexité d'un système, comme JESS, peut s'évaluer de la manière suivante :

$$R.F^P$$

où R est le nombre de règles, F le nombre de faits et P le nombre moyen de patrons (conditions à vérifier) par règle.

Ainsi, la complexité augmente fortement lorsque les règles nécessitent de nombreux faits pour être activées. Aussi est-il préférable d'élaborer de nombreuses règles simples qu'une seule règle complexe. Afin de réduire le temps d'exécution du système, une solution serait de compiler la base de règles sous la forme d'un arbre de décision.

- Les règles

La conception de la base de connaissances peut paraître, dans certains cas, difficile à mettre en oeuvre. En effet, l'élaboration de la connaissance sous la forme de simples règles n'est pas forcément possible. Dans ce cas, une approche pour extraire la connaissance automatiquement est nécessaire. Il est possible d'élaborer une base de règles à l'aide d'arbres de décision (Huang et Jensen, 1997).

#### - Le transfert de la connaissance

Pour introduire la connaissance dans la base, il faut écrire les règles dans le langage du système. En l'occurrence, Jess utilise Clips, qui est assez répandu dans le monde de l'IA. Malheureusement, la transcription des règles peut être laborieuse et nécessite souvent un cognitifien. L'expert ne peut pas réaliser directement cette traduction.

#### 2.5.6.2. Les arbres de décision

Contrairement aux systèmes à base de règles, l'arbre de décision est formé grâce à un ensemble d'observations. La méthode consiste à représenter simplement cet ensemble par un arbre de classification. Selon Friedl et Brodley (1997), on peut identifier plusieurs groupes d'arbres de décision. Les *arbres univariés* utilisent un seul attribut pour le test de chaque noeud. Cette approche est la plus répandue dans les travaux de télédétection, c'est pourquoi elle sera détaillée dans la suite (Friedl et Brodley, 1997; Huang et Jensen, 1997). Les *arbres multivariés* utilisent une combinaison d'attributs pour établir leurs tests. La première approche découpe l'espace des observations en hypercubes dont les frontières ne respectent pas vraiment la réalité. L'association de deux attributs permet de trouver des limites plus subtiles entre les classes. La dernière approche s'appelle les *arbres hybrides*. Elle permet de prendre en compte plusieurs sortes d'algorithmes de classification, telles que les deux premières approches, mais aussi d'autres méthodes, comme la méthode des  $k$  plus proches



voisins. Cette approche s'explique par le fait qu'une seule et même méthode n'offrira pas forcément de bonnes performances sur tout l'ensemble des observations. Ainsi, chaque sous-ensemble d'observations bénéficie de l'algorithme le plus adapté.

L'algorithme présenté dans la suite est inspiré de CART de Breiman (Breiman *et al.*, 1984).

#### a) La structure de l'arbre

L'arbre est composé de noeuds et de feuilles (figure 2.8). Chaque noeud représente une condition sur un attribut. Les feuilles se retrouvent aux extrémités de chaque branche. Elles symbolisent les classes possibles. Le premier noeud est appelé noeud-racine (root). Lorsqu'un objet est présenté au noeud-racine, on se déplace alors dans l'arbre suivant les conditions vérifiées.

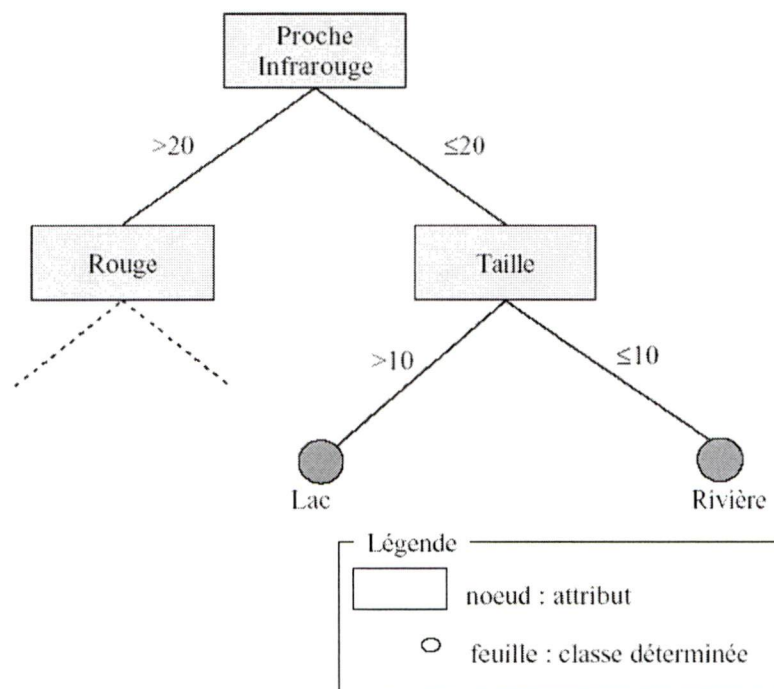


Figure 2.8: Exemple d'un arbre de décision

Lorsqu'une feuille est atteinte, la progression est arrêtée et la nature de l'objet est déterminée par la classe que symbolise cette feuille.

L'arbre de décision est une représentation classique de la résolution d'un problème. Cette approche est utilisée pour les problèmes techniques qui nécessitent une succession de vérifications. Un expert peut alors définir la succession des tâches à réaliser pour résoudre le problème. Dans certains cas, il est difficile de construire cet arbre. Si l'application dispose de suffisamment d'observations, il est alors possible de le construire automatiquement.

#### b) La construction automatique de l'arbre

Il existe de nombreuses façons de construire automatiquement un arbre. Nous présentons l'approche utilisée par la méthode ID3 et C4.5 (extension de ID3), qui utilise la mesure du gain en entropie (Quinlan, 1986). L'utilisateur dispose d'un ensemble de données, qui représente les observations. Il s'agit donc de représenter cet ensemble de données par un arbre. Ainsi, lorsqu'une nouvelle observation sera disponible, il sera possible de la classer à l'aide de l'arbre.

Dans un premier temps, il faut trouver l'attribut le plus discriminant de cet ensemble de données. La méthode ID3 utilise l'entropie qui mesure l'homogénéité de l'information dans un ensemble de données. Elle se calcule ainsi :

$$Entropie(P) = -(p_1 \cdot \log(p_1) + p_2 \cdot \log(p_2) + p_3 \cdot \log(p_3) + \dots + p_n \cdot \log(p_n)) \quad (2.2)$$

où  $p_c$  représente la probabilité des exemples de la classe  $c$  dans l'ensemble  $P$ .

Le meilleur attribut est donc celui qui sépare un grand ensemble en plusieurs sous-ensembles de données plus homogènes. Pour mesurer cette caractéristique, le gain en entropie (*Gain*) est utilisé.

$$Gain(X, P) = Entropie(P) - Entropie(A, P) \quad (2.3)$$

avec

$$Entropie(A, P) = \sum_{x=0}^X \frac{|P_x|}{|P|} \cdot Entropie(P_x) \quad (2.4)$$

où  $X$  est le nombre de valeurs possibles de  $A$  (attribut).

Le *Gain* est calculé pour chaque attribut  $X$  et celui qui est le plus important est conservé. On utilise alors cet attribut comme noeud de l'arbre. Le résultat du noeud donne des sous-ensembles. Chaque sous-ensemble passe par la même procédure que précédemment. La procédure est recommencée jusqu'à ce que toutes les feuilles de l'arbre aient été trouvées.


L'arbre obtenu par la méthode ci-dessus peut être de grande taille (on parle de profondeur de l'arbre). Pour optimiser l'arbre, il est important de vérifier la signification de chaque branche. Pour cela, on enlève la branche à étudier et on teste l'arbre avec un ensemble de vérification. Si le résultat ne varie pas beaucoup avec ou sans cette branche, alors elle est superflue. L'arbre obtenu après vérification est alors dit "élagué" (pruned).

#### c) Avantages et inconvénients

La méthode ID3 ne permet pas de considérer l'information des attributs continus, comme un indice de végétation ou un paramètre de texture. Une extension C4.5 contourne le problème en discrétisant l'information. Dans ce cas, l'information est alors découpée en plusieurs intervalles. Cette extension est nécessaire en interprétation automatique pour pouvoir manipuler tous les types d'attributs de l'objet.

L'arbre de décision permet d'extraire rapidement la connaissance d'un ensemble d'observations. Cette méthode est considérée en IA comme une technique d'apprentissage automatique, puisque la structure de l'arbre peut être retranscrite par un ensemble de conditions *si ... alors ...* (Huang et Jensen, 1997). L'arbre de décision rehausse donc les principales caractéristiques de l'ensemble d'observations. Le résultat de cette méthode est facilement compréhensible par un humain.

L'arbre représente l'espace des observations par des hypercubes. Malheureusement, cette représentation est très restrictive. Afin d'évaluer les différentes approches, nous avons créé une image test avec des objets de différentes formes. La figure 2.9 montre un exemple de difficultés observées, lorsque les classes ne peuvent pas être englobées dans un hypercube. Les limites des classes étant alors fausses, cela se traduit sur la figure par une approximation des contours des ellipses.



**Figure 2.9:** Illustration de l'approximation des ensembles par l'arbre

Ce problème peut conduire à une mauvaise identification d'un objet, si certaines valeurs de ses attributs sont proches des limites des classes.



### 2.5.6.3. Les réseaux de neurones

Il existe plusieurs groupes de réseaux : simple couche (ex : Hopfield), multi-couches (ex : Perceptron Multi-Couches (PMC)) et à carte topographique (ex : Kohonen). À l'exception des réseaux à carte auto-organisatrice (méthode Kohonen), l'apprentissage est en général dirigé. Les différentes architectures donnent à chacun de ces réseaux des capacités particulières. Le tableau 2.1 présente quelques-unes des applications.

**Tableau 2.1: Applications des réseaux les plus connus**

|                           | PMC | Hopfield | Kohonen |
|---------------------------|-----|----------|---------|
| <b>Classification</b>     | X   | X        | X       |
| <b>Aide à la décision</b> | X   |          | X       |
| <b>Optimisation</b>       |     | X        | X       |


Le PMC est certainement le réseau le plus utilisé dans les algorithmes de classification et les outils d'aide à la décision. Dans la partie suivante, nous présentons en détail le perceptron multi-couche.

#### a) La structure du réseau PMC

Le PMC est un des réseaux de neurones les plus simples. Il est composé en général d'une couche d'entrée, d'une couche de sortie et d'une ou plusieurs couches cachées. Le nombre de neurones de la couche d'entrée correspond au nombre d'attributs à évaluer (taille du vecteur d'attributs). La couche de sortie se rapporte au nombre de classes désirées. La structure des couches cachées est dictée par la complexité du problème à résoudre.

Le neurone est un sommateur dont la réponse est déterminée par une fonction d'activation. En général, il s'agit d'une sigmoïde pour le perceptron.

$$f(a) = \frac{1}{1 + e^{-a}} \quad (2.5)$$



**Figure 2.10: Exemple d'un réseau de neurones**

où  $a = \sum_{i=0}^M w_i \cdot f_i$ ,  $w_i$  et  $f_i$  sont respectivement le poids et la valeur d'activation associée au neurone  $i$  de la couche précédente.  $M$  est le nombre de neurones de la couche précédente.

#### b) L'apprentissage

L'apprentissage ajuste les poids à l'entrée de chaque neurone. Le réseau perceptron utilise l'apprentissage par rétropropagation de l'erreur (Backpropagation).

L'erreur totale du réseau représente la somme des erreurs partielles. Elle est calculée selon la relation suivante :

$$E_{tot} = \sum_{p=0}^P \sum_{j=0}^S \frac{1}{2} \cdot (t_j^p - o_j^p)^2 \quad (2.6)$$

où  $P$  est le nombre d'exemples présentés au réseau.  $S$  est le nombre de neurones de la couche de sortie.  $t_j^p$  et  $o_j^p$  sont respectivement la sortie désirée et la sortie obtenue avec les poids actuels pour l'exemple  $p$  et le neurone  $j$ .

La correction des poids s'effectue de la manière suivante :


$$\Delta W = -\eta \cdot \nabla Etot \quad (2.7)$$

$W$  représente la matrice des poids pour l'exemple  $p$ . Le gradient de l'erreur globale ( $\nabla Etot$ ) permet de corriger plus ou moins fortement la valeur des poids.  $\eta$  est appelé taux d'apprentissage. Il est contrôlé par l'utilisateur et permet de diminuer le temps d'apprentissage.

L'apprentissage se termine lorsque l'erreur globale  $Etot$  a une valeur inférieure à un seuil prédéfini par l'utilisateur. Si le réseau ne converge pas, il est aussi possible de limiter le nombre de fois que l'ensemble d'apprentissage est présenté à l'entrée du réseau. Parfois le réseau ne convergera pas vers une structure stable, cette deuxième option évite que le réseau se trouve dans une boucle sans fin. Pour éviter de se trouver dans un minimum local, un terme *momentum* peut être ajouté à la relation 2.7,  $\alpha \cdot \Delta W_{prcdent}$ .  $\alpha$  est déterminé par l'utilisateur au début de l'apprentissage.

### c) Avantages et inconvénients


Contrairement à l'arbre de décision, le réseau de neurones ne découpe pas l'espace en hypercubes. Il peut ainsi s'adapter plus précisément au problème.



**Figure 2.11: Approximation par le réseau de neurones**

La figure 2.11 illustre le fait que le réseau tente de correspondre au mieux à l'ensemble de données. Dans ce cas, il n'y a pas d'artefacts (effet d'escalier) aux frontières des classes.

Malheureusement, la détermination de la structure du réseau est complexe. Les nombres de couches et de neurones cachés ne sont pas évidents à déterminer. La structure du réseau influence beaucoup le résultat. La figure (2.12) montre la différence de deux réseaux ayant un nombre de neurones cachés différents.



**Figure 2.12: Réseau de neurones avec une couche cachée, 5 neurones cachés (à gauche) et 9 (à droite).**

Pour déterminer la structure du réseau, la plupart des travaux proposent de réaliser des tests avec des réseaux de structure différente. Il s'agit d'entraîner le réseau sur un ensemble d'entraînement et de le valider sur un ensemble de validation. L'évaluation du réseau pourra se faire grâce au calcul du  $Kappa$  (voir le paragraphe 3.7.1.2.).

Les autres paramètres sont aussi difficiles à déterminer, le taux d'apprentissage et le momentum. Des taux mal adaptés risquent d'augmenter le nombre d'itérations ou de faire osciller le réseau autour d'une position stable. Une solution est de diminuer le taux d'apprentissage en fonction du nombre d'itérations. Cette astuce permet au réseau de s'affiner au fur et à



mesure que l'ensemble d'apprentissage est présenté.

Contrairement à l'arbre de décision, le réseau de neurones ne permet pas une lecture explicite de la connaissance accumulée. En effet, celui-ci est uniquement composé de poids et de fonctions d'activation. Mais des travaux existent sur la transformation de la structure du réseau en règles compréhensibles par l'homme, notamment grâce à la méthode *crisp* (Wlodzislaw *et al.*, 1997). Une telle approche permet d'utiliser le réseau de neurones comme une méthode d'extraction de la connaissance.

Un dernier inconvénient est la taille du vecteur d'entrée. Dans le cas de l'interprétation, il s'agit du nombre d'attributs de l'objet. Ce vecteur affecte le nombre de neurones de la couche d'entrée, par conséquent la taille des matrices de poids. Dans la littérature, certains auteurs effectuent une réduction de la taille de ce vecteur, soit par une analyse en composantes principales ou par l'élimination des attributs trop corrélés (Benediktsson et Sveinsson, 1997). Ceci permet de réduire la structure du réseau et par la même occasion le temps d'apprentissage.

## 2.6. Conclusion partielle

La détection du changement et l'interprétation de données sont très distincts du point de vue de la recherche. Depuis peu de temps, on tente d'introduire des méthodes intelligentes dans la détection du changement. Cette orientation de la recherche provient de plusieurs constatations. D'abord, l'identification des zones perturbées est souvent mieux réalisée par un être humain. Actuellement les méthodes automatiques ne prennent pas en compte tous les critères d'interprétation, surtout la connaissance. Deuxièmement l'arrivée des nouveaux capteurs à THRS et radar nécessite le développement de nouvelles méthodes. Par exemple, la THRS exige des approches reproduisant le processus de vision humaine (Mayer, 1999). Dans ce cas, des approches capables d'imiter l'homme dans cette tâche sont nécessaires.

La télédétection utilise les systèmes intelligents depuis 20 ans, pourtant elle commence à peine à être utilisée en détection du changement. Ce retard dans l'utilisation de ces nouvelles approches s'explique surtout par le fait que les premiers travaux de l'application de l'intelligence à la télédétection n'ont pas vraiment satisfait les chercheurs. Ces méthodes étaient souvent utilisées pour répondre à des problèmes trop complexes. Certains paramètres étaient difficiles à déterminer, comme la structure des réseaux de neurones ou la base de connaissances pour les systèmes à base de règles. Les solutions opérationnelles basées sur les méthodes intelligentes sont en général destinées à de simples tâches (Tsatsoulis, 1993). Dans le cas d'une reconnaissance de forme, l'extraction des primitives de l'objet sera réalisée par une méthode analytique alors que l'identification pourra être effectuée par un réseau de neurones. La solution est donc de faire collaborer les deux types de méthodes.

Avant d'envisager l'utilisation d'un système intelligent, il est important d'évaluer la nécessité d'une telle méthode. En général, l'approche intelligente peut permettre de dépasser les limitations des méthodes conventionnelles. En classification, ces méthodes intègrent plus de types d'informations que les méthodes conventionnelles. Elles permettent de gérer l'expérience et la connaissance. Mais l'application a-t-elle vraiment besoin de ces caractéristiques ? Si une méthode intelligente est choisie alors plusieurs options existent, les méthodes à apprentissage automatique ou dirigé. Le choix dépend uniquement de la connaissance *a priori* dans le domaine d'application. Est-ce que cette connaissance existe et peut-elle être exprimée sous forme de règles ?

Il est important de faire cette brève analyse, car cela permet de mieux utiliser l'intelligence dans les applications de la télédétection.

### 3. Développements méthodologiques

La méthodologie consiste à mettre en place une approche de détection du changement permettant l'utilisation de systèmes intelligents. Le système intelligent réalise uniquement la correction de la méthode classique. Un système à base de règles est proposé pour cette tâche. Les résultats de ce système sont comparés à deux autres approches à apprentissage par l'exemple.

#### 3.1. Méthodologie générale

La figure 3.1 illustre le cheminement choisi pour mettre en place le système intelligent de détection du changement. L'approche se décompose en deux grandes parties, le traitement d'image et les systèmes intelligents. La première partie concerne l'extraction de l'information et la détection du changement. La deuxième partie consiste à la mise en place des différents systèmes intelligents utilisés dans cette étude.

Le cheminement suit 6 étapes :

- 1) choix de la méthode de détection du changement ;
- 2) constitution de l'approche orientée objet ;
- 3) mise en place et modification du système à base de connaissances ;
- 4) constitution de règles pour identifier les changements ;
- 5) élaboration des autres systèmes de décision (réseau de neurones et arbre de décision) ;
- 6) tests et validation.

L'étape 1 définit la méthode de détection du changement choisie pour cette étude. L'étape 2 permet de mettre en place des critères d'identification similaires à ceux de l'interprète. Les étapes 3 à 5 permettent d'avoir trois systèmes intelligents en analyse d'image. La dernière

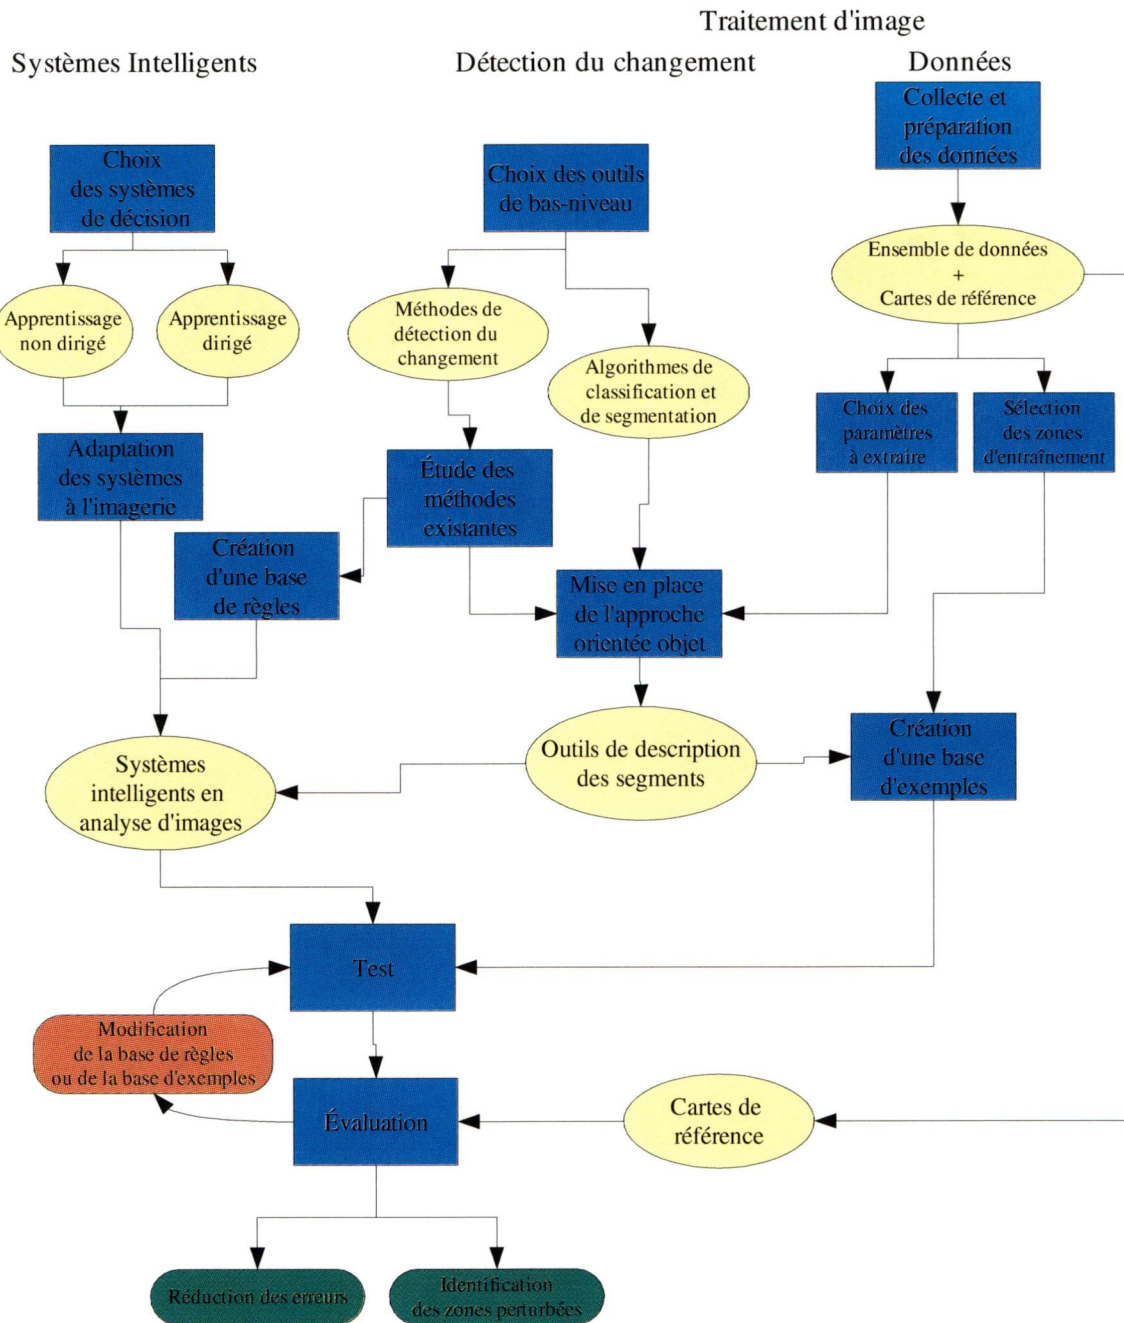


Figure 3.1: Démarche conceptuelle



étape consiste à valider et comparer les différentes approches.

Ces étapes sont détaillées dans la suite du chapitre.

### 3.2. L'approche pour la détection du changement

La première étape consiste à sélectionner la méthode de détection du changement la plus appropriée. La figure 3.2 illustre la stratégie proposée pour réaliser la mise à jour de la carte. Il s'agit de mettre en place une méthode classique et de lui associer un système intelligent. Deux alternatives sont représentées sur la figure.

Une des objectifs du projet SITI est de pouvoir mettre à jour une carte numérique existante. De nombreuses méthodes existent, mais seulement deux utilisent les informations des classes thématiques, l'analyse post-classification (APC) et l'analyse par corrélation croisée (ACC). Les cartes des zones changées sont obtenues par une analyse par pixels de l'image. L'approche par régions est introduite après cette première étape.

L'ACC ne permet pas de relever les changements causés par la phénologie du plant. Or, cette étude s'intéresse à toutes les classes de changement, notamment les zones en régénération naturelle.

L'APC nécessite l'utilisation d'un résultat de classification. Les méthodes dirigées ont été préférées, et en particulier, une méthode basée sur la distance de Mahalanobis. Cette méthode permet de tenir compte de la forme de la distribution de chaque classe. Celle-ci est souvent utilisée dans les applications de la télédétection. Elle utilise uniquement des données spectrales. D'autres méthodes peuvent être envisagées, comme le maximum de vraisemblance. L'étude dans cette thèse n'effectue pas l'évaluation de la méthode de classification, c'est pourquoi une seule méthode de classification est utilisée. Nous privilégions la méthode APC.

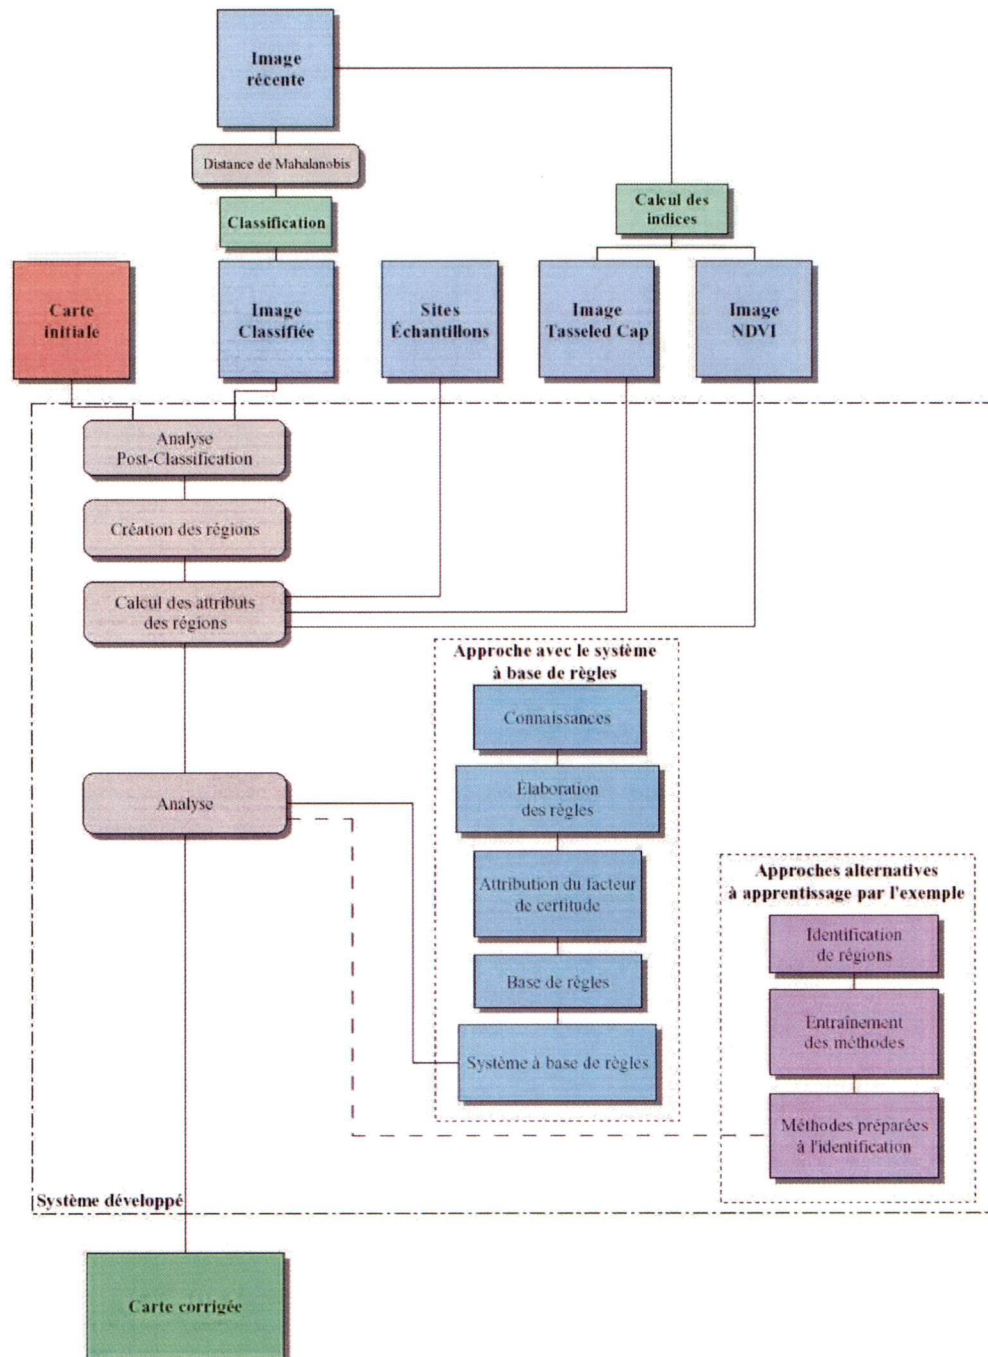



Figure 3.2: Procédure de mise à jour

### 3.3. L'approche orientée objet

La constitution de l'approche orientée objet s'effectue en deux temps, l'élaboration des régions et la définition des attributs.

#### 3.3.1. La création des régions

La description des régions est effectuée après l'APC. Les régions sont élaborées en fonction de la classe d'origine et de la nouvelle classe de chaque pixel. Tous les pixels décrivant une même évolution formeront donc une même région (figure 3.3).



**Figure 3.3: Création des segments**

Chaque région est ensuite décrite selon les attributs géométriques et radiométriques. Certains attributs correspondent à la moyenne d'un paramètre pour cette région (ex : les indices de végétation). Les régions sont considérées suffisamment homogènes pour que la moyenne d'un attribut soit représentative.

Dans la suite du chapitre, le terme objet est utilisé pour représenter la région décrite par une série d'attributs. Chaque objet conserve aussi la liste de ses voisins, ce qui permet de prendre en compte l'information contextuelle spatiale. Par exemple, l'objet 5 dans la figure

3.3 a 5 voisins (1,3,4,6,7).

Cette approche par objet peut aussi fonctionner si elle est appliquée sur un seul résultat de classification. L'approche a été développée pour un fonctionnement dans un cadre général.

### 3.3.2. Les attributs des régions

De nombreux attributs sont calculés pour chaque région. Les paramètres de texture, quelques indices de végétation et d'autres grandeurs géométriques sont aussi calculés. L'étude est basée sur les paramètres les plus utilisés dans la littérature. Ces paramètres doivent permettre d'établir des règles d'identification.

#### 3.3.2.1. Les indices de végétation

Les indices de végétation sont corrélés avec des caractéristiques spectrales de la cible. Ils permettent généralement de distinguer certaines classes végétales, notamment les résineux, les feuillus et les zones agricoles. En détection du changement, il est intéressant de connaître l'évolution d'un indice de végétation.

Les indices peuvent être facilement intégrés dans un système intelligent. Roy *et al.* (1996) ont utilisé des indices de végétation, comme le AVI (Advanced Vegetation Index), BI (Bare Soil Index) et SI (Shadow Index), pour classer, selon la densité, des zones forestières en Inde. Ils ont élaboré une série de règles suivant la relation entre ces indices et la couverture végétale.

Les indices de végétation ne sont pas forcément une source fiable. Effectivement certains indices sont perturbés par l'atmosphère ou encore subissent une forte contribution du sol. On observe aussi une saturation dans l'infrarouge lorsque la densité du couvert est trop élevée. Ce problème affecte les indices de végétation qui utilisent cette fenêtre spectrale, notamment



le NDVI (Normalized Difference Vegetation Index).

Pour cette étude, on choisit de compléter le NDVI à l'aide du ARVI (Atmospherically Resistant Vegetation Index), qui est un indice plus résistant aux effets atmosphériques.

$$\text{NDVI} = \frac{\text{PIR} - R}{\text{PIR} + R} \quad (3.1)$$

$$\text{ARVI} = \frac{\text{PIR} - RB}{\text{PIR} + RB} \quad (3.2)$$

$$RB = R - \gamma \cdot (B - R) \quad (3.3)$$

PIR = canal Proche-InfraRouge, R = Rouge, B = Bleu.  $\gamma$  dépend de la réflectance de l'atmosphère, avec 1 comme valeur usuelle.

D'autres indices peuvent être trouvés dans Bannari *et al.* (1995) . Pour cette étude, les indices de Kauth et Thomas (1976) ont été aussi utilisés, car ils apparaissent dans de nombreux travaux de détection du changement. Ils sont obtenus par transformation linéaire des bandes du satellite LANDSAT.

$$\begin{bmatrix} \text{Brightness} \\ \text{Greenness} \\ \text{Wetness} \end{bmatrix} = \begin{bmatrix} 0.3037 & 0.2793 & 0.4743 & 0.5585 & 0.5082 & 0.1863 \\ -0.2848 & -0.2435 & -0.5436 & 0.7243 & 0.0840 & -0.1800 \\ 0.1509 & 0.1973 & 0.3279 & 0.3406 & -0.7112 & -0.4572 \end{bmatrix} \cdot \begin{bmatrix} \text{TM1} \\ \text{TM2} \\ \text{TM3} \\ \text{TM4} \\ \text{TM5} \\ \text{TM7} \end{bmatrix}$$

Le principe de cette transformation est d'identifier la contribution du sol, de la végétation et de l'eau dans la signature spectrale de la cible. Ainsi le premier indice donne une information

sur la brillance du sol (brightness). Le deuxième indice dépend de la teneur en végétation "verte" de la surface (greenness). Le troisième indice est lié à l'humidité de la surface (wetness). L'intérêt de ces indicateurs est de pouvoir suivre la phénologie d'un couvert.

Quelques exemples dans la littérature montrent l'utilité des indices de végétation dans la détection du changement :

- Lorena *et al.* (2002) ont utilisé les indices de Kauth et Thomas ;
- Patterson et Yool (1998) ont utilisés les mêmes indices pour les zones brûlées ;
- avec ces indices, Coppin *et al.* (2001) ont surveillé les changements de végétation verte ;
- Hayes et Sader (2001) ont employé le NDVI pour les zones de repousse.

La figure 3.4 illustre l'importance des indices de Kauth et Thomas dans l'identification du changement. Cette figure a été obtenue sur la zone du Labrador.

La région 1 identifiée dans la figure correspond aux classes où la brillance du sol et la teneur en végétation verte est forte. On y retrouve les zones en régénération naturelle. Tandis que dans la région 2, la teneur en végétation verte est faible et la brillance du sol est forte ; on y retrouve les coupes et les routes.

Le déplacement des indices de Kauth et Thomas permet d'identifier le type de changement. Effectivement, ces indicateurs ont tendance à se déplacer dans le temps. Les points de la région 1 vont progressivement rejoindre le nuage de points composé, entre autres, par les classes forestières. De même, les points (rouge pour les coupes) de la région 2 se dirigeront progressivement vers la région 1 à cause de l'apparition de la repousse sur les zones coupées. Ces caractéristiques permettent d'établir des règles d'identification.





Figure 3.4: Les indicateurs de végétation verte et de brillance du sol

Des constatations analogues peuvent être faites pour les autres indices. La figure 3.5 montre le déplacement des indices NDVI et ARVI entre 1988 et 1999 sur la zone du Labrador.

Les régions inchangées pendant cette période, comme les routes ou les lacs, montrent peu de variation sur les indices. Tandis que les indices de végétation pour les régions ayant subi une perturbation durant cette période révèlent une forte variation.

### 3.3.2.2. Le contexte spatial

Le contexte spatial est souvent utilisé dans les méthodes d'analyse par pixels de l'image, notamment dans les approches markoviennes. Il permet de réduire les erreurs. Effectivement, un pixel isolé peut correspondre à une erreur de la méthode de classification. Celui-ci a une



**Figure 3.5: Variations des indices NDVI et ARVI sur les classes thématiques du Labrador**

classe complètement différente de celle de ses voisins. L'analyse du contexte peut permettre d'attribuer une classe plus probable à ce pixel isolé. Les méthodes de post-classification, comme ICM (Iterative Conditional Mode), réalisent une telle analyse. D'une manière plus simple, le filtre majoritaire corrige le pixel isolé en lui attribuant la classe la plus représentée dans un certain voisinage. Dans une approche orientée objet, le contexte spatial consiste à prendre en compte les objets voisins à l'objet à identifier.

### 3.3.2.3. La géométrie

Les éléments du milieu urbain révèlent de nombreuses formes géométriques tandis que le milieu naturel est plus aléatoire. La forme peut parfois permettre de différencier deux éléments dont la radiométrie est proche. En l'occurrence, une coupe a une réponse spectrale proche d'une route, mais une forme totalement différente.



Les régions perturbées sont des zones artificiellement créées par l'homme dans le milieu naturel, notamment les coupes. Les coupes et les zones en régénération naturelle ont en général une forme compacte sur le site d'étude. De nombreux paramètres peuvent être calculés, nous utilisons uniquement l'indice de compacité pour discriminer une zone artificielle d'une zone naturelle.

La compacité se calcule à partir de l'aire et du périmètre de la région :

$$\text{Compacité} = \frac{\text{Périmètre}^2}{4\pi \text{Aire}} \quad (3.4)$$

Une compacité proche de 1 signifie que la forme tend vers un disque. Si la forme est quelconque, alors cette valeur est très forte.

La taille et le périmètre de la région sont en même temps calculés, car ces deux paramètres sont nécessaires à la compacité. De plus, ils seront utilisés dans les règles pour identifier les régions.

#### 3.3.2.4. La situation géographique

Chaque région est localisée par les coordonnées de la zone rectangulaire géographique qui englobe la région analysée. Par ailleurs, la distance entre deux régions peut être connue.

### 3.4. Le système à base de connaissances

Le système JESS (Java Expert System Shell) a déjà été utilisé en analyse d'image (Kabanza *et al.*, 2000). Kabanza *et al.* présentent dans ce travail un système intelligent pour le suivi environnemental. Une des limitations du système est un temps de raisonnement important causé par une analyse pixel à pixel de l'image. De plus, l'approche par pixel se limite à

quelques critères et elle ne permet pas la mise en place de règles complexes. Ces problèmes avaient déjà été constatés dans (Tsatsoulis, 1993).

Une nouvelle approche est donc proposée pour le problème d'interprétation du changement à l'aide du système expert JESS. Des informations sur le système expert peuvent être trouvées dans (Friedman-Hill, 2003). Avant de former la base de connaissances, il est nécessaire d'établir le fonctionnement du système à base de règles et de l'adapter aux contraintes de l'application.

### 3.4.1. Représentation symbolique d'un objet

L'information issue de l'image ne peut pas être directement utilisée par le système. Effectivement, les règles du système sont activées uniquement par des faits présents dans sa mémoire de travail. Pour appliquer la base de connaissances à tous les segments de l'image, il est nécessaire de retranscrire le segment en une structure symbolique dans le langage *CLIPS*.

Les lignes suivantes sont un extrait de l'objet dans la base de connaissances. On retrouve l'identifiant pour chaque objet, la taille, le périmètre, le rayon minimum et maximum, les coordonnées du centre de masse, les coordonnées du rectangle englobant.

```
(deftemplate object
  (slot number (type NUMBER))
  (slot size (type NUMBER))
  (slot peri (type NUMBER))
  (slot rmin (type NUMBER))
  (slot rmax (type NUMBER))
  (slot xc (type NUMBER))
  (slot yc (type NUMBER))
  (slot xmin (type NUMBER))
  (slot ymin (type NUMBER)))
```

```

    (slot xmax (type NUMBER))
    (slot ymax (type NUMBER))
    ...
)

```

Cette structure permet le passage de la région de l'image en un fait. La région devient donc un objet abstrait, ce qui permet d'élaborer des règles, telles que :

```

?f<-(object (number ?number) (size ?size:&(< 10 ?size)))
=>
(printout t "objet " ?number "est de petite taille" crlf)

```

Ces quelques lignes montrent la traduction d'une règle dans la base de connaissances. Cette règle peut se traduire par "trouver les objets dont la taille est inférieure à 10."

Ainsi, la structure symbolique de l'objet permet d'élaborer des règles assez claires et proches de celles utilisées par un humain. D'autres exemples de règles en langage *CLIPS* sont donnés dans l'annexe II.

### 3.4.2. La création de la base de règles

Dans cette partie, il s'agit d'élaborer l'organisation de la base et le mode de raisonnement. De plus, il faut instaurer une stratégie de combinaison des règles. L'élaboration des règles spécifiques pour le problème de la détection du changement s'effectue une fois la structure de la base définie.

#### 3.4.2.1. L'organisation

Les règles sont classées selon plusieurs groupes :

- règles de fonctionnement (gestion des faits et de la mémoire) ;
- règles générales (applicables à toutes les classes) ;
- règles spécifiques à chaque classe.

Il est nécessaire de bien organiser la base, car celle-ci risque de prendre de l'ampleur au fil du temps. La gestion de la base est délicate, c'est pourquoi il est important d'avoir un système de classement des règles. L'ajout et la modification des règles deviennent alors plus faciles.

La base de connaissances peut être partagée selon plusieurs bases spécialisées pour chaque type de données. Ainsi, il s'agit de charger dans la mémoire du système uniquement les règles relatives à un type d'image.

Dans ce travail, les règles de fonctionnement ne sont pas présentées. Elles permettent simplement de gérer la mémoire de travail et les faits. Elles n'interviennent pas directement dans l'interprétation.

#### 3.4.2.2. La description d'une règle

La règle se traduit dans la base de connaissances de la manière suivante :

**si attribut(s) vérifié(s) alors déduction.**

Chaque règle possède un facteur de certitude. En général, le facteur de certitude de la règle est donné grâce au paramètre "saliency" dans JESS. Ce paramètre permet en cas de conflit de donner plus d'importance à une règle. En effet, lorsque plusieurs règles sont activées, le moteur d'inférence se charge selon une stratégie de déterminer celle qui est la plus envisageable. Dans ce cas, le moteur choisit une seule règle parmi toutes celles activées. Dans l'approche développée dans cette étude, toutes les déductions des règles activées sont considérées et combinées entre elles. Le facteur de certitude est illustré dans l'exemple suivant :



Si  $NDVI < 0,3$  alors je suis à 80 % sûr que c'est un sol nu. La méthode pour calculer le NDVI n'est pas forcément exacte et cette valeur peut être perturbée par l'atmosphère. On peut attribuer une confiance sur le NDVI de 0,8. L'information "sol nu" aura donc une probabilité de 0,64 ( $0,8 \times 0,8$ ) selon cette règle.

Dans cet exemple, l'information utilisée pour la condition possède un degré de confiance de 0,8. Certaines informations peuvent être obtenues avec plus ou moins d'exactitude. Le NDVI étant plus sensible aux effets atmosphériques que l'ARVI, on peut donc convenir que la confiance pour l'ARVI est plus forte que celle pour le NDVI. Ce degré de confiance est combiné avec le facteur de certitude de la règle pour fournir le degré de confiance sur la déduction.

#### 3.4.2.3. Le facteur de certitude d'une règle

Le facteur de certitude est compris entre -1 et 1. Si le facteur de certitude de la règle est négatif, cela signifie qu'il est probablement impossible d'atteindre la conclusion avec les faits utilisés. Par contre, si celui-ci est positif, la règle peut conduire à une conclusion avec un degré de confiance plus ou moins élevé.

Le facteur de certitude permet de traduire l'incertitude sur l'élaboration des règles. En réalité, il est rarement possible de trouver des règles pour lesquelles on est sûr à 100 %. Actuellement ce facteur est établi par un expert en fonction de sa connaissance.

#### 3.4.2.4. La combinaison

L'intérêt du système à base de règles vient du fait de la combinaison de plusieurs règles. Différentes règles peuvent être activées pour un objet. Il faut donc pouvoir combiner efficacement leur déduction. En effet, plus il y a de sources qui conduisent à une conclusion, plus

cette conclusion est envisagée.

Cette stratégie a déjà été mise en place dans le système MYCIN, mais elle n'est pas utilisée par JESS. Il faut donc constituer cette approche dans le système. Celle-ci s'explique de la manière suivante :

soit deux règles,  $R1$  et  $R2$ , conduisant à la même conclusion  $C$  à partir de faits différents  $F1$  et  $F2$  :

$$R1 : F1 \longrightarrow C$$

$$R2 : F2 \longrightarrow C$$

Le facteur de certitude pour la conclusion  $C$  s'exprime alors :

$$CF[C, \{F1, F2\}] = f(CF[C, \{F1\}], CF[C, \{F2\}])$$

$$\text{où } f(x, y) = \begin{cases} x + y - xy & \text{if } x, y > 0 \\ x + y + xy & \text{if } x, y < 0 \\ \frac{x+y}{1-\min(|x|, |y|)} & \text{dans les autres cas.} \end{cases}$$

Si plusieurs règles conduisent à la même identification, la certitude sur l'identification de l'objet est renforcée. Par contre si une règle contredit la déduction d'une autre règle, alors cette certitude diminue.

Illustration par un exemple :

La confiance sur toutes les informations est égale à 1,0.

Si  $NDVI < 0,3 \Rightarrow$  sol nu à 80 %

si  $brightness > 30 \Rightarrow$  sol nu à 80 %

si  $greenness > 5 \Rightarrow$  sol nu impossible à 70 %

Après l'activation de la première règle, la probabilité que l'objet est un sol nu est de 0,8. En tenant compte de la relation précédente, si les deux premières règles sont activées, la probabilité d'avoir un sol nu est de 0,96. Les deux règles conduisent à une même conclusion, ce qui renforce la certitude. Si toutes les règles sont activées, alors cette probabilité est de 0,87.

Cette approche est souvent utilisée dans les méthodes de fusion multi-sources. Les approches classiques de fusion combinent généralement l'information spatiale. Le système à base de connaissances peut combiner des sources d'information très diverses, spatiales et non spatiales, grâce aux règles de la base.

### 3.4.3. Mécanisme de raisonnement

Le système JESS permet la mise en oeuvre de différents mécanismes. Dans notre étude, le mécanisme par chaînage avant a été utilisé, car il représente le principe de déduction utilisé en interprétation.

Bien que le mécanisme soit relatif au fonctionnement du moteur d'inférences, il influence la création des règles. En réalité, l'écriture des règles sera complètement différente selon le mécanisme choisi.

## 3.5. Élaboration des règles pour l'identification du changement

L'architecture de la base de connaissances étant définie, l'élaboration des règles peut alors débuter. Les différents types de règles pour l'identification sont présentés dans la suite.

### 3.5.1. Règles simples sur un attribut

Ce type de règle revient à comparer la valeur d'un attribut de l'objet à un seuil. Par exemple, il s'agit de déterminer si un objet est plutôt de petite taille.


Les règles sur les indices de végétation entrent directement dans cette catégorie. Les travaux utilisant les indices pour détecter les changements vérifient si l'indice varie d'une image à l'autre. Or, dans notre étude, nous disposons de l'information spectrale de la deuxième acquisition et de l'ancienne carte thématique. Dans ce cas, l'étude de la variation de l'indice ne peut pas être utilisée. Par contre, il est possible d'observer si l'indice actuel correspond à la nature de la région analysée.

Dans le cas d'une ancienne zone forestière, si l'indice de végétation actuel est plutôt faible alors il y a une possibilité de perte de biomasse. Ainsi l'indice NDVI ou le "greenness" seront assez faibles par rapport aux mêmes indices d'une autre forêt (figure 3.5). Cette indication peut signifier que l'ancienne forêt a été coupée. Par ailleurs, la confirmation de cette constatation peut être fournie par l'indice de "brillance". Si celui-ci est fort cela signifie que le sol nu contribue énormément dans cette région.

D'un autre côté, sur notre site au Labrador, des zones en régénération naturelle devraient succéder aux anciennes coupes. Dans ce cas, les indices de végétation, tels que le NDVI, devraient augmenter vers les fortes valeurs (figure 3.5). L'indice de brillance du sol diminue en même temps. Cette variation sera visible sur les images satellitaires au bout de 2 à 3 ans.

Pour prendre en compte la force des indices, une approche similaire à la logique floue a été utilisée (figure 3.6). Les limites sont déterminées par l'utilisateur en fonction du site d'étude à partir d'une série de tests. Elles sont relatives à chaque indice utilisé.





**Figure 3.6: Méthode de détermination de la classe de l'indice**

Cette approche évite de définir des seuils trop stricts et permet d'introduire un certain flou dans les limites. Par ailleurs, elle permet la traduction d'une valeur numérique en un terme compréhensible par le système.

### 3.5.2. Règles sur le contexte spatial


Le contexte spatial peut influencer de deux manières la nature de l'objet analysé. D'une part, l'objet a de fortes chances d'être de la même nature qu'un objet voisin. Il est possible de trouver une coupe à proximité d'une autre coupe. D'autre part, la présence de certains éléments dans le voisinage d'une région fournit aussi des indices sur sa nature. Une coupe peut être aussi identifiée grâce à la présence d'un accès à proximité, comme une route. Un exemple est donné dans l'annexe II.

### 3.5.3. Règles sur les sites d'entraînement

Dans la procédure traditionnelle, l'interprète utilise souvent des échantillons pour élaborer les clés d'interprétation. Ces échantillons ont été récoltés au cours de campagnes de relevés sur le terrain. La localisation de ces zones est très importante, puisque la nature de ces zones et leur situation géographique ont été certifiées par l'interprète. En analyse d'image, ces

zones sont déjà utilisées comme des zones d'entraînement pour les méthodes dirigées. Dans ce cas, l'information spectrale est uniquement utilisée. La localisation géographique des sites n'est pas prise en compte dans les méthodes classiques.

Identique à la méthode de classification des *k plus proche voisins* (Haapanen *et al.*, 2004), le système expert prend en compte les caractéristiques spectrales et la localisation des sites d'échantillonnage. La nature de la région peut alors être influencée par les échantillons qui se situent à une certaine distance (figure 3.7). La figure représente la région analysée par le système ainsi que quatre sites d'entraînement. Le système vérifie alors si la région est de la même nature que les sites compris dans la zone de tolérance (les sites 1 et 2 sur la figure).



**Figure 3.7: Les sites d'entraînement**

Dans notre approche, les échantillons pris en compte sont ceux qui ont des caractéristiques spectrales identiques à celles de l'objet à identifier (il s'agit donc du site 2). Le calcul de la distance de Mahalanobis permet de vérifier si les caractéristiques sont proches :

La distance entre deux vecteurs  $\vec{x}$  et  $\vec{y}$  est donnée par la relation suivante :

$$D_{Mahalanobis}^2 = (\vec{x} - \vec{y})^t \cdot C^{-1} \cdot (\vec{x} - \vec{y})$$

où  $C$  représente la matrice de covariance.

La distance de Mahalanobis est plus adaptée pour une analyse discriminante car elle tient compte de l'orientation de la distribution dans l'espace. Si  $C$  est égale à la matrice identité, on retrouve la distance Euclidienne. Actuellement, peu de méthodes en analyse d'image prennent en compte la localisation des échantillons. Le système à base de règle permet d'intégrer cette information sous la forme de règles. Un exemple est donné dans l'annexe II.

#### 3.5.4. Règles sur l'occupation du sol


La surface terrestre évolue en fonction du temps. En l'occurrence le couvert végétal décrit un cycle dans le temps (la phénologie). Bien que ce soit le même couvert, cette surface vue à différente saison aura une apparence différente. En milieu agricole, le temps permet de discriminer les cultures entre elles en tenant compte de la saison des récoltes. En utilisant un automate temporel, Largouet (2001) a pu modéliser la rotation des cultures. La prédiction de l'automate était utilisée pour réduire la confusion d'un résultat de classification.

Dans le cadre de la détection du changement, l'occupation du sol peut s'exprimer selon des règles dans le système. Une classe perturbée, telle qu'une coupe, peut apparaître après certaines classes, en l'occurrence les zones forestières. Les règles expriment la probabilité de passage d'une classe vers une autre classe. Elles intègrent aussi le temps écoulé pour effectuer la transition.

Par exemple, une coupe a de fortes chances d'apparaître après une région forestière. Le temps écoulé peut être inférieur à une année. Une régénération naturelle apparaît en général quelques années après une coupe.

Cette approche permet d'éliminer les transitions peu probables causées par la confusion entre deux classes. Par ailleurs, certains changements ne seront pas considérés, car la période entre deux acquisitions d'images est trop courte pour faire apparaître ce type de changement.

La figure 3.8 représente un cas simple de transition.



**Figure 3.8: Exemple de cycle du changement**

### 3.5.5. Règles sur les erreurs

Un des défis du système est de pouvoir distinguer les erreurs parmi les zones réellement perturbées. La procédure de détection du changement fait apparaître des erreurs dans le résultat. Il n'est pas nécessaire d'identifier d'où provient l'erreur, par contre, il est important de la repérer. Les erreurs sont en fait identifiables grâce à plusieurs indications :

- ce sont souvent des segments de petite taille qui n'ont aucun lien avec le contexte (bruit dans les données) ;
- il s'agit d'une transition improbable ou non désirée, comme un marais devenant une forêt peu dense ;
- la zone ne vérifie aucune hypothèse d'un changement classique.

Il est possible de traduire ces constatations sous la forme de règles dans la base de connaissances. La stratégie est de remplacer la classe actuelle de l'objet par l'ancienne. Dans ce cas,



l'information de la carte initiale est privilégiée. Cette stratégie peut dépendre de la certitude que l'on accorde à chaque source d'information.

### 3.6. Les systèmes basés sur l'apprentissage par l'exemple

Un intérêt de ce travail est d'évaluer le système à base de règles par rapport aux méthodes d'apprentissage par l'exemple. La difficulté pour mettre en place une base de connaissances peut conduire l'utilisateur vers les méthodes à apprentissage par exemple. Deux méthodes sont généralement choisies, le réseau de neurones et l'arbre de décision. Il est donc important d'évaluer la précision de ces méthodes.

#### 3.6.1. La représentation de l'objet

La base d'exemples ressemble à une liste d'objets identifiés par l'utilisateur (tableau 3.1). Les attributs de l'objet sont les mêmes que ceux utilisés dans l'approche précédente.

**Tableau 3.1: La base d'exemples**

| numéro | taille | périmètre | x min | y min | x max | y max | Classes |
|--------|--------|-----------|-------|-------|-------|-------|---------|
| ...    | ...    | ...       | ...   | ...   | ...   | ...   | ...     |

La même base d'exemples est utilisée par les deux méthodes.

#### 3.6.2. Problème de la définition des classes

Il y a deux façons d'aborder le problème de l'identification du changement pour ce type de méthodes. La première consiste à identifier les classes de changement et de considérer toutes les autres classes comme inchangées. Par exemple, une route peut être une classe inchangée aussi bien qu'un lac. La deuxième manière est de considérer toutes les classes présentes dans

la scène. Dans ce cas, la classe dite "inchangée" n'existe pas (tableau 3.2).

**Tableau 3.2: Deux approches pour définir les classes**

| Approche 1            | Approche 2            |
|-----------------------|-----------------------|
| Classes inchangées    | Forêts                |
|                       | Marais                |
|                       | Lacs                  |
|                       | Routes                |
|                       | ...                   |
| Coupes                | Coupes                |
| Zones en régénération | Zones en régénération |

Les deux approches ont été évaluées. Il est alors apparu que la première approche était moins efficace. En effet, le principe de regrouper dans une même classe des éléments "lac" et "route" semble un problème. La classe devient alors très hétérogène et les statistiques de cette classe ne sont pas très représentatives. Cette approche entraîne une confusion et ne permet pas aux méthodes automatiques de trouver des attributs discriminants.

La deuxième approche est utilisée pour cette étude.

### 3.6.3. La sélection des exemples

La sélection des exemples s'effectue comme les sites d'entraînement par l'identification des zones connues dans la scène. Le choix des sites et des exemples peut être effectué en même temps.

### 3.6.4. La considération du contexte spatial

Pour utiliser le contexte spatial, les approches automatiques nécessitent une adaptation. Le réseau de neurones et l'arbre de décision peuvent facilement utiliser cette information dans une approche par pixel. Dans cette approche, le nombre de voisins est constant, contraire-

ment à une approche par objet. Or, la conservation des exemples dans une base nécessite une structure constante de l'objet. Les objets doivent avoir un même nombre d'attributs dans la base (voir tableau 3.1).

Le nombre de classes présentes dans l'image est constant. Il est possible d'ajouter comme attribut de l'objet les différentes classes possibles. Le tableau 3.3 montre la modification la base d'exemples.

**Tableau 3.3: La base d'exemples avec contexte spatial**

| numéro | taille | périmètre | ... | Road | Forest | Lake | Classes |
|--------|--------|-----------|-----|------|--------|------|---------|
| ...    | ...    | ...       | ... | ...  | ...    | ...  | ...     |

La valeur de l'attribut est la fréquence d'apparition de la classe dans le voisinage de l'objet. Le contexte spatial est élaboré d'une manière différente dans le système expert.

### 3.6.5. Choix relatifs à l'arbre de décision

L'arbre de décision choisi est la méthode C4.5 souvent utilisée en analyse d'image. La méthode est disponible dans la librairie Weka (Witten et Frank, 1999). Afin d'obtenir un arbre plus simple, l'élagage est utilisé. Les autres paramètres demeurent à leur valeur par défaut.

### 3.6.6. Choix relatifs au réseau de neurones

Le réseau est le perceptron multi-couches disponible aussi dans la librairie Weka. C'est le réseau le plus répandu pour l'analyse d'image.

#### 3.6.6.1. Les paramètres

Le réseau Perceptron multicouches nécessite un certain nombre de paramètres pour son fonctionnement. Le taux d'apprentissage est choisi avec une valeur initiale de 0,4. Le taux

décroît avec le nombre d'itérations. Ceci évite au réseau d'osciller autour d'une position en fin d'apprentissage. En effet, un taux constant ne permet pas d'affiner les poids.

### 3.6.6.2. La structure

Pour mettre en place le réseau de neurones, il est nécessaire d'établir le nombre de neurones cachés. Le nombre de neurones ne peut pas être établi selon une règle. Ainsi le principe est d'élaborer la structure optimale par des tests.

La figure 3.9 illustre le principe. L'ensemble d'apprentissage est séparé en deux groupes. Le premier est utilisé pour entraîner le réseau et le second permet l'évaluation de l'entraînement. Cette distinction est nécessaire afin de réaliser une meilleure évaluation du réseau. Le taux de bonne classification est utilisé pour estimer la précision du réseau sur le second ensemble.

Dans un premier temps, le nombre de neurones est choisi aléatoirement. Ce nombre devrait se situer entre le nombre de neurones de sortie et le nombre de neurones d'entrée. Il faut choisir une couche cachée pour débiter. Le problème ne devrait pas nécessiter plus de deux couches cachées. La structure est évaluée. Dans un deuxième temps, le nombre de neurones cachés est augmenté. Si le taux de bonne classification est amélioré, la procédure est recommencée. Dans l'autre cas, le précédent réseau est conservé.

## 3.7. L'évaluation des résultats

### 3.7.1. Les critères

Pour évaluer le système à base de connaissances, il est nécessaire de mettre en place des critères. En l'occurrence deux points nous intéressent : la réduction des erreurs et l'identification des zones perturbées. Le système à base de règles est évalué par rapport à des méthodes classiques, mais aussi par rapport aux autres systèmes intelligents.



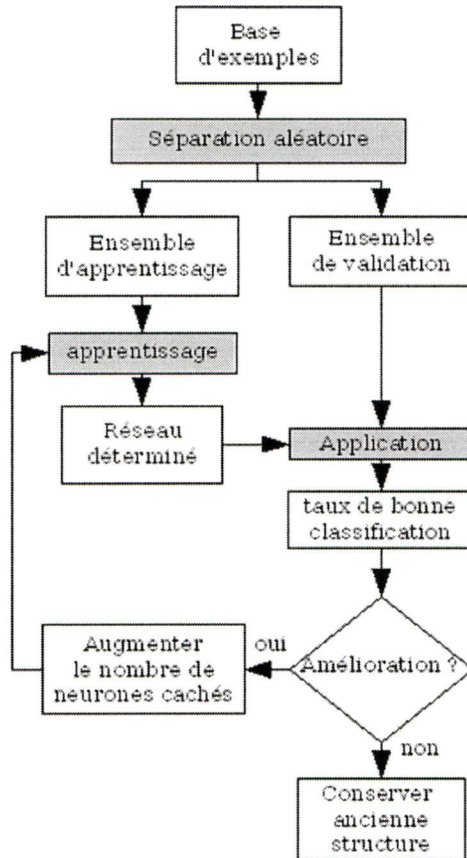


Figure 3.9: Procédure pour déterminer le réseau

#### 3.7.1.1. La matrice de confusion

La plupart des critères d'évaluation sont extraits de la matrice de confusion (tableau 3.4).

Tableau 3.4: Matrice de confusion

|                     |          | Image de référence    |                       |     |                       | Total                       |
|---------------------|----------|-----------------------|-----------------------|-----|-----------------------|-----------------------------|
|                     |          | Classe 1              | Classe 2              | ... | Classe N              |                             |
| Classifi-<br>cation | Classe 1 | $a_{11}$              | $a_{12}$              | ... | $a_{1n}$              | $\sum_{K=1}^N a_{1K}$       |
|                     | Classe 2 | $a_{21}$              | $a_{22}$              | ... | $a_{2n}$              | $\sum_{K=1}^N a_{2K}$       |
|                     | ...      | ...                   | ...                   | ... | ...                   | ...                         |
|                     | Classe N | $a_{n1}$              | $a_{n2}$              | ... | $a_{nn}$              | $\sum_{K=1}^N a_{nK}$       |
| Total               |          | $\sum_{K=1}^N a_{K1}$ | $\sum_{K=1}^N a_{K2}$ |     | $\sum_{K=1}^N a_{KN}$ | $N = \sum_{I,K=1}^N a_{ij}$ |

Dans cette étude, la précision pour les classes de perturbation est conservée. Les autres classes ne sont pas pertinentes pour l'étude. Effectivement, la base de règles est élaborée uniquement pour les zones perturbées.

La matrice permet aussi d'estimer *kappa* pour l'ensemble des classes de perturbation.

### 3.7.1.2. Calcul de *Kappa* (K)

Le coefficient Kappa permet de mesurer l'accord entre deux sources d'information. Dans notre cas, il s'agit d'évaluer la concordance entre la vérité terrain et l'image classifiée par les différentes approches.

$$K = \frac{P_0 - P_e}{1 - P_e} \quad (3.5)$$

$P_0$  représente la proportion d'accord et  $P_e$  la proportion d'accord aléatoire.

$$P_0 = \sum_{K=1}^N a_{KK} \quad (3.6)$$

$$P_e = \sum_{K=1}^N a_{+K} * a_{K+} \quad (3.7)$$

$a_{K+}$  : total marginal de la ligne K.

$a_{+K}$  : total de la ligne K.

*Kappa* tient compte de tous les éléments de la matrice. Ce coefficient permet de mesurer si le résultat de l'interprétation concorde sur l'ensemble des classes.

### 3.7.1.3. Le taux de bonne détection

Ce critère mesure uniquement la précision de la méthode de détection du changement. Dans ce cas, il s'agit d'évaluer la proportion des zones réellement perturbées qui ont été bien détectées.

Il est défini ainsi : Taux de bonne détection =  $\frac{\text{Régions détectées par la méthode}}{\text{Régions réellement perturbées}}$

### 3.7.1.4. Le taux de fausses alarmes

Pour évaluer l'aptitude des méthodes à réduire les erreurs, il est nécessaire de calculer le taux de fausses alarmes. Dans ce cas, il s'agit de la proportion de zones normalement inchangées sur le terrain qui ont été relevées par la méthode de détection.

Il est défini ainsi : Taux de fausses alarmes =  $\frac{\text{Régions détectées par la méthode}}{\text{Régions non perturbées}}$

Le taux est évalué avant et après le passage des différentes approches.

### 3.7.1.5. La précision de l'identification

L'estimation de l'identification est réalisée à partir de la matrice de confusion. Il s'agit des valeurs diagonales  $a_{ii}$  pour les différentes classes de perturbation.

## 3.7.2. Les Études

Afin de mieux caractériser l'approche proposée, plusieurs études sont nécessaires.

### 3.7.2.1. Sensibilité par rapport à l'information utilisée

Le système à base de connaissances intègre diverses sources d'informations. Il peut notamment manipuler des informations temporelles, spatiales et contextuelles spatiales. Il est donc important de vérifier si le choix des sources d'informations influence la précision du résultat final.

Cette étude doit permettre de comprendre si toutes les règles sont nécessaires. Dans une application future du système, il est possible que certaines informations ne soient pas disponibles ou encore de mauvaise qualité. La question est de savoir si cela risque d'influencer la qualité du résultat final.

### 3.7.2.2. Base de règles par rapport à la base d'exemples

La méthodologie proposée dans cette étude permet de réaliser cette analyse. En général, cette partie n'est jamais réalisée, car il est très difficile de mettre en place les deux apprentissages dans une même étude.

Les méthodes, telles que le réseau de neurones et l'arbre de décision, sont alors appliquées au même ensemble de données. Ces méthodes autorisent aussi l'intégration d'un grand nombre d'informations, comme pour le système expert. Le résultat de cette analyse permet de dire si la base de règles est nécessaire pour la résolution du problème ou si une simple méthode à apprentissage automatique peut réaliser la même chose.

### 3.7.2.3. Conservation de la connaissance

L'un des intérêts de la base de règles est la conservation de la connaissance dans le temps. Cette base rend possible la reproduction d'un processus dans le temps sans forcément refaire l'apprentissage. Il est important de vérifier si les règles élaborées à une date précise peuvent



être utilisées dans le futur. Cette vérification est réalisée grâce à la série temporelle acquise sur le Labrador.

#### 3.7.2.4. Sensibilité au facteur de certitude

L'un des problèmes majeurs du système à base de règles est la détermination du poids d'une règle. Effectivement, il n'existe pas vraiment de méthode pour établir le poids des règles automatiquement. Si le facteur de certitude est déterminé par l'utilisateur, il est important de connaître l'incidence d'une mauvaise détermination du poids des règles.

#### 3.7.2.5. Comparaison avec les méthodes traditionnelles

La détection du changement comprend de nombreuses méthodes. Notre approche est basée sur l'une d'entre elles, l'analyse post-classification. Il est intéressant de comparer le système à base de connaissances avec certaines méthodes généralement utilisées en détection du changement. Cette étude évalue donc les forces et les faiblesses de l'approche proposée par rapport à certaines méthodes de la littérature. Les méthodes choisies sont la différence d'images, l'analyse en composantes principales, l'analyse par corrélations croisées et l'analyse post-classification.

### 3.8. Conclusion partielle

La méthodologie proposée permet d'évaluer la pertinence de la base de règles pour une détection du changement. De plus, les différentes études réalisées permettent de relever les limitations de cette approche. Les critères établis pour l'étude, tels que le taux de bonne détection et de fausses alarmes, doivent permettre de mesurer le gain avec un tel système.

Le temps d'obtention d'un résultat n'a pas été pris en compte comme critère d'évaluation. D'abord, le système à base de règles est plus lent que les autres méthodes automatiques. Il raisonne sur chaque cas, ce qui peut être long. Ce temps dépend beaucoup de la complexité

des règles. Ensuite nous avons préféré comparer la précision pour l'identification des classes des méthodes sur le résultat final.

## 4. Application

Ce chapitre se décompose en trois parties. Premièrement, les données artificielles et réelles utilisées pour l'étude sont présentées. Les choix méthodologiques pour cette étude sont ensuite justifiés. Finalement, les différents résultats sont présentés et analysés.

### 4.1. Les ensembles de données

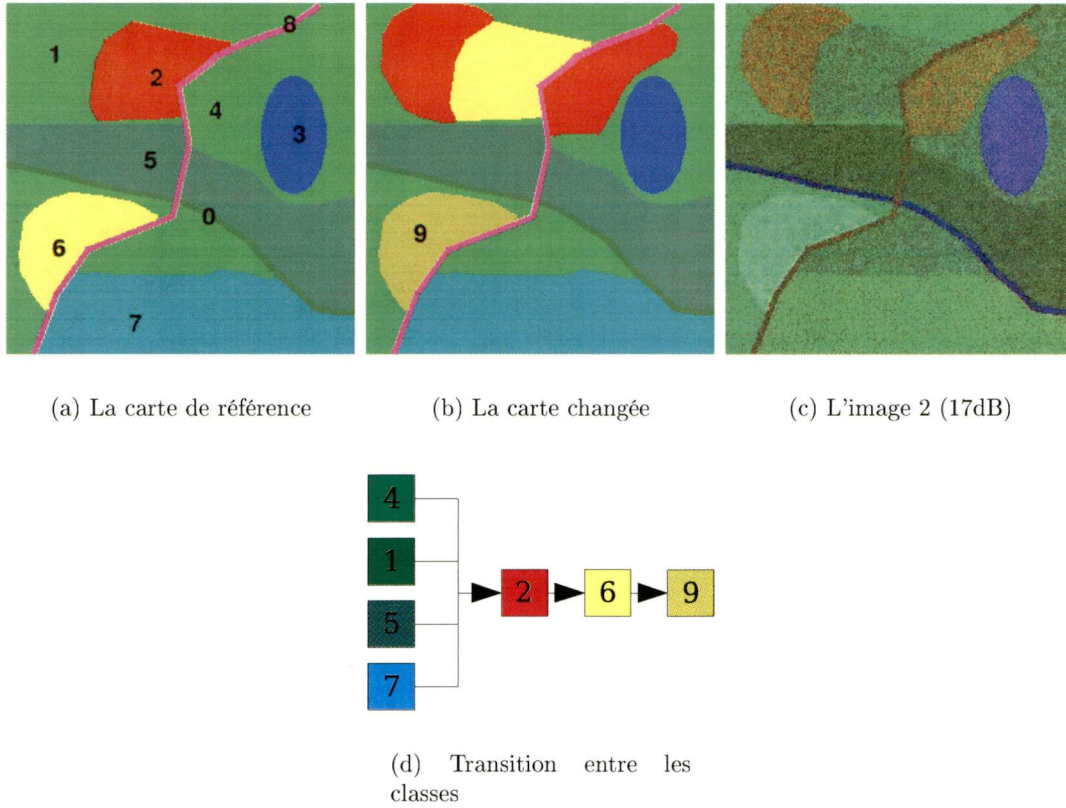
#### 4.1.1. Les images artificielles

Une scène artificielle a été créée pour évaluer l'approche. Cette image de 256 x 256 pixels représente une scène avec 9 classes. Pour obtenir l'imperfection inhérente aux images, un bruit a été ajouté. Des bruits d'importance différente ont été ajoutés à la scène originale (tableau 4.1) pour obtenir des images avec un degré de difficulté différent. L'image 1 est considérée comme faiblement bruitée, alors que l'image 2 est fortement bruitée. De plus, certaines classes ont des caractéristiques spectrales similaires pour augmenter la confusion entre les classes.

**Tableau 4.1: Rapport signal sur bruit pour chaque image**

| Images  | S/B (en dB) |
|---------|-------------|
| Image 1 | 24          |
| Image 2 | 17          |

Les images simulées permettent de s'affranchir des problèmes liés à l'acquisition d'une scène réelle, tels qu'un possible décalage géométrique et une modification des conditions atmosphériques entre deux acquisitions. Le travail réalisé dans cette étude se focalise uniquement sur les problèmes liés à l'utilisation d'un mauvais résultat de classification.



**Figure 4.1: Données simulées**

Par ailleurs, l'avantage des images simulées est de pouvoir caractériser parfaitement l'évolution temporelle de la scène. La figure 4.1 a) représente la carte initiale simulée et la figure 4.1 b) la carte actualisée. L'image 4.1 c) est une des deux images bruitées utilisée pour la mise à jour. La figure 4.1 d) donne les changements possibles pour cette scène. Les classes (1,4,5,7) sont susceptibles d'être affectées à la classe (2). La classe (2) peut devenir (6), alors que cette dernière se transformera en (9). Dans cette scène simulée, les classes perturbées sont donc (2), (6) et (9).


#### 4.1.2. Les données réelles

Le deuxième ensemble de données permet d'utiliser l'approche dans un cas réel.



#### 4.1.2.1. Présentation de la région

Le Centre canadien de télédétection (CCT) a fait l'acquisition de plusieurs données sur le Labrador. La figure 4.2) représente les 3 principaux sites disponibles au Labrador (Lac Melville (jaune), Goose Bay (vert) et Grand Lake (bleu)). Le site de "Grand Lake" a été choisi, car il fait apparaître des zones fortement perturbées. Le site d'étude est représenté sur la figure (figure 4.3).



**Figure 4.2: Localisation des sites d'étude**

Ces dernières années, cette région a subi de nombreuses coupes forestières. Bien que la zone soit exploitée, aucune mise à jour de la carte forestière n'a été réalisée depuis la période de 1988-90. Le CCT a réalisé au cours de ces 5 dernières années des campagnes de terrain qui ont permis de suivre l'évolution de cette région.




Figure 4.3: Image LANDSAT-7 (ETM) de Juillet 2000

Ces campagnes sont accompagnées d'acquisition d'images satellitaires, notamment des images LANDSAT-5 (TM), LANDSAT-7 (ETM) et une image Ikonos (tableau 4.2). Les différentes données sont présentées dans les figures 4.5 et 4.6.

**Tableau 4.2: Données disponibles pour l'étude**


| Données          | Date              | Résolution |
|------------------|-------------------|------------|
| Carte forestière | 1987-89           | 30 m       |
| MNA              |                   | 30 m       |
| LANDSAT-5 (TM)   | 20 Septembre 1987 | 30 m       |
| LANDSAT-5 (TM)   | 4 Juillet 1988    | 30 m       |
| LANDSAT-5 (TM)   | 26 Juillet 1999   | 30 m       |
| LANDSAT-5 (TM)   | 27 Août 1999      | 30 m       |
| LANDSAT-7 (ETM)  | 13 Juillet 2000   | 30 m       |
| LANDSAT-7 (ETM)  | 01 Août 2001      | 30 m       |
| Ikonos           | 11 Novembre 2001  | 1 - 4 m    |

Afin de réduire les problèmes liés à la phénologie, la plupart des images ont été acquises à la même saison. Cependant, l'image IKONOS a été prise au mois de Novembre. Les coupes et les zones en régénération sont couvertes par un manteau neigeux, ce qui permet de les distinguer plus facilement des autres classes. D'un autre côté, la neige diminue la variabilité locale des niveaux de gris.

La carte de 1989 a été obtenue par interprétation de photographies acquises de 1987 à 1989. Cette carte est précise quant à l'identification des régions. Cependant, le nombre de classes a été réduit afin de correspondre avec les classes définies sur les images LANDSAT.

Le site d'étude présente trois types de changement (figure 4.4) :

- les coupes : il s'agit du passage d'une zone forestière à un sol nu (en magenta sur la figure 4.4) ;



**Figure 4.4: Suivi des zones changées avec les images LANDSAT, composé coloré (5,4,3)**

- les zones en régénération naturelle (stade 1) : elles apparaissent après une coupe (en vert-jaune) ;
- les zones en régénération naturelle (stade 2) : elles apparaissent après la classe précédente (en vert).

La succession temporelle des classes peut se représenter selon le graphique suivant :

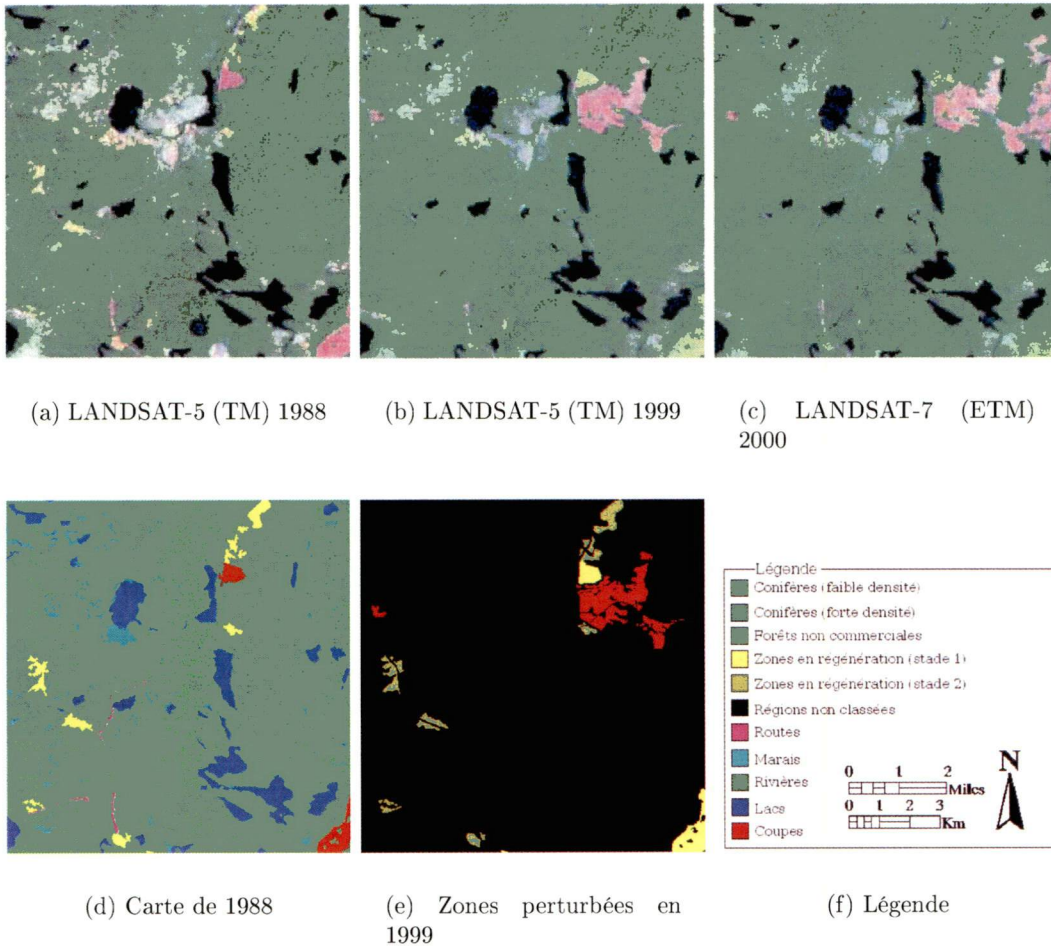
Zone forestière → Coupe → régénération (stade1) → régénération (stade2)

Les photographies aériennes et les campagnes de terrain ont permis d'identifier les différents changements. Par ailleurs, une interprétation de l'image Ikonos a permis d'obtenir les différentes régions perturbées en 2001. L'interprétation réalisée par Mr Michel Yergeau du Cartel a permis de confirmer la localisation et l'identification des régions.

#### 4.1.2.2. La zone de test


Une zone de test a été extraite des scènes LANDSAT (zone UTM 20 U). Les coordonnées de la zone sont 641 880E, 5 949 900N ; 652 650E, 5 939 880N.





**Figure 4.5: Ensemble de données à moyenne résolution spatiale**

Afin de pouvoir comparer les images entre elles, les scènes acquises en juillet ont été conservées. La radiométrie des classes non perturbées (végétation, lacs, etc...) est semblable d'une image à l'autre. Par ailleurs, les images ont été corrigées des effets atmosphériques. Cette particularité est importante pour mettre en place les méthodes classiques de détection du changement.



**Figure 4.6: Image Ikonos de 2001 (canaux RGB)**

La saison d'acquisition de l'image Ikonos n'étant pas la même, la comparaison radiométrique avec les autres images n'est pas possible. Il est donc nécessaire d'utiliser les classes thématiques.

#### 4.1.2.3. La préparation des données

La détection du changement nécessite des données comparables aussi bien radiométriquement que géométriquement. Bien que certaines méthodes soient moins sensibles aux problèmes radiométriques, il est nécessaire de bien corriger les données. En effet, certains paramètres, comme les indices de végétation, sont sensibles à l'atmosphère.

L'étape de prétraitement correspond à la mise en forme des données sous forme d'images exploitables par un système de traitement d'image. Ces opérations modifient la nature des données et risquent d'altérer les données elles-mêmes ; certains auteurs conseillent de ne pas effectuer de corrections radiométriques mais plutôt une inter-calibration des données (Tokola *et al.*, 1999). Dans notre cas, la plupart des données ont été corrigées par le CCT suivant la méthode des cibles de référence sur le terrain. Une vérification des corrections a été faite.

a) Les images à moyenne résolution spatiale

Les images ont dû être recalées par rapport à la carte forestière de référence afin que toutes les images soient superposables. Le site d'étude ne permet pas de nombreux points de contrôle, c'est pourquoi nous avons choisi les centres de masse de lacs présents dans l'image. Cette technique a permis de positionner toutes les données avec une erreur totale inférieure à 0,5 pixel. L'effet de cette erreur n'est pas discuté dans ce travail.

b) L'image à très haute résolution spatiale

Nous avons à notre disposition une image Ikonos acquise le 11 novembre 2001. Cette image a été corrigée géométriquement par le CCT, mais la correction radiométrique a été effectuée selon la méthode 6S grâce à des cibles connues, telles que les lacs non recouverts de neige. Les coefficients de calibration utilisés sont fournis par la compagnie Space Imaging.

#### 4.1.2.4. La signature spectrale des classes

Le CCT a défini, à la suite des campagnes, les 10 classes suivantes :

- coupe totale (classe 1) ;
- zone en régénération naturelle (classe 2) ;
- forêt mixte (classe 3) ;
- forêt résineuse peu dense (classe 4) ;

forêt résineuse dense (classe 5);  
 forêt friche (classe 6);  
 marais (classe 7);  
 lac (classe 8);  
 rivière (classe 9);  
 route (classe 10).

La confusion spectrale entre les classes peut être une des raisons du manque de précision de la procédure classique, notamment pour l'analyse post-classification. En effet, une mauvaise définition des classes peut entraîner des erreurs dans la classification. La méthode de classification utilisée est une méthode dirigée. Il est donc important de bien choisir les sites d'entraînement. Le tableau 4.3 montre la séparabilité calculée (distance de Jeffries-Matusita) sur l'image LANDSAT de 1999.

**Tableau 4.3: Séparabilité des classes pour l'image Landsat de Juillet 1999**

| Peu<br>denses | Denses       | Regen.1 | Coupes | Lacs  | Friches | Routes       | Marais       |            |
|---------------|--------------|---------|--------|-------|---------|--------------|--------------|------------|
| 2,000         | 2,000        | 1,889   | 2,000  | 2,000 | 1,994   | 1,963        | 1,878        | Regen.2    |
|               | <u>1,825</u> | 2,000   | 1,997  | 2,000 | 1,986   | 1,998        | 1,993        | Peu denses |
|               |              | 2,000   | 2,000  | 2,000 | 2,000   | 2,000        | 2,000        | Denses     |
|               |              |         | 1,988  | 2,000 | 1,993   | <u>1,775</u> | <u>1,607</u> | Regen.1    |
|               |              |         |        | 2,000 | 1,998   | <u>1,958</u> | 1,971        | Coupes     |
|               |              |         |        |       | 2,000   | 2,000        | 2,000        | Lacs       |
|               |              |         |        |       |         | 1,905        | 1,954        | Friches    |
|               |              |         |        |       |         |              | <u>1,635</u> | Routes     |

La distance de Jeffries-Matusita est faible pour les valeurs soulignées (inférieure à 1,9), ce qui risque d'entraîner une confusion entre les classes concernées. Les marais sont des classes très difficiles à définir spectralement, c'est pourquoi ils peuvent se confondre avec d'autres classes. Il apparaît que cette classe est confondue avec les classes dont la contribution du sol



est forte, comme les zones en régénération, les routes, et les coupes.

En ce qui concerne les classes de perturbation, les coupes et les zones en régénération (1 et 2) ont des caractéristiques spectrales proches des marais et des routes.

Le tableau 4.3 illustre le fait que certaines classes végétales peuvent être difficiles à définir uniquement avec l'information spectrale. Effectivement, la dénomination des classes provient de la carte initiale de 1989. Celle-ci a été obtenue par photo-interprétation. Cette technique permet d'obtenir des classes plus précises qu'une méthode de classification automatique. Il est important de conserver les mêmes classes entre la carte d'origine et la classification, si l'on utilise l'analyse post-classification. En observant la matrice de séparabilité des classes (tableau 4.3), on remarque que l'utilisation des sites d'entraînement peut causer une confusion dans le résultat de la classification. Le choix des sites a été réalisé à la suite de plusieurs expériences ; la matrice conservée est celle qui procure le moins de valeur inférieure à 1,9. La matrice illustre aussi le fait que l'utilisation uniquement de l'information spectrale ne permet pas forcément de discriminer certaines classes, comme les zones perturbées.

## **4.2. Choix méthodologiques**

### **4.2.1. Les approches classiques**

La base de règles est comparée aux résultats obtenus avec les méthodes automatiques de détection du changement. Les procédures retenues sont composées d'une méthode automatique de détection et d'identification du changement. Les approches classiques sont uniquement effectuées selon une analyse par pixels de l'image. Les autres méthodes proposées sont basées sur une approche par régions.

#### 4.2.1.1. La détection du changement

La première étape consiste à obtenir le masque des zones changées. Quatre méthodes de détection ont été envisagées pour cette étude :

- la différence d'image (indice NDVI) ;
- l'analyse en composantes principales (ACP) ;
- l'analyse par corrélation croisée (ACC) ;
- l'analyse post-classification (APC).

Les deux premières méthodes utilisent uniquement l'information spectrale et les deux dernières utilisent la classe thématique (carte de référence). La différence d'image et l'ACP n'ont pas été appliquées sur les images simulées, parce que l'ensemble de données simulées comprend uniquement une carte thématique de référence. De plus, les images simulées ne permettent pas l'utilisation des indices de végétation. Le même problème existe pour l'image Ikonos.

#### 4.2.1.2. L'identification du changement

L'identification des zones est réalisée à l'aide d'une classification dirigée utilisant le critère de la distance minimale. Il s'agit de classer les pixels sous le masque obtenu dans la première phase.

### 4.2.2. Méthodes d'optimisation de résultat de classification

La méthode APC utilise un résultat de classification, qui peut être amélioré par un post-traitement. Deux méthodes sont envisagées, le filtre majoritaire et la méthode ICM (Iterative Conditional Mode). Pour l'ICM, la valeur de  $\beta$  est fixée à 0,7.  $\beta$  favorise l'homogénéité spatiale entre les pixels voisins. La valeur choisie correspond à la valeur par défaut pour un voisinage de 3 x 3.

### 4.3. Présentation et analyse des résultats

Les résultats sont décomposés en trois parties. La première concerne l'évaluation du système à base de règles sur des données artificielles. La seconde se rapporte à l'utilisation du système dans un cas réel pour la moyenne résolution spatiale. La dernière partie concerne les résultats préliminaires sur la très haute résolution spatiale.

#### 4.3.1. Évaluation du système sur les données simulées

Les données simulées ne présentent pas autant de difficultés que les données réelles. Les résultats obtenus dans cette partie permettent de caractériser le comportement du système dans une situation peu complexe.

##### 4.3.1.1. Définition des règles

La base de règles est élaborée à partir des constatations suivantes :

- un objet proche d'un site d'entraînement est possiblement de même nature que ce site. Cette règle est valide si les caractéristiques spectrales de l'objet sont proches de celles du site (E) ;
- un objet peut avoir la même classe qu'un de ces voisins (C) ;
- les classes (1,4,5,7) peuvent devenir une classe 2 (T) ;
- la classe 2 peut devenir une classe 6 (T) ;
- la classe 6 peut devenir une classe 9 (T) ;
- les autres changements de classes sont considérés comme des erreurs. Dans ce cas, l'ancienne classe est privilégiée (T) ;
- les régions, dont la taille est faible et dont la classe est différente du voisinage, peuvent être la cause d'une erreur (C).

Une fois traduite en langage *CLIPS*, les constatations sont équivalentes à 12 règles. Les règles ont été classées selon 3 groupes C (contexte spatial), T (transition ou occupation du sol) et E (sites d'entraînement). Cette notation est utilisée dans la suite du travail.

#### 4.3.1.2. Les approches classiques par rapport à l'approche modifiée

Deux méthodes classiques de détection ont été appliquées sur les données simulées (tableau 4.4). Ces approches consistent à mettre à jour une carte thématique (simulée) existante avec une image récente de la scène.

**Tableau 4.4: Résultats de la détection pour les images simulées (en %)**

| Méthode       | Bonne<br>détection | Fausse<br>alarmes | Seuils choisis |
|---------------|--------------------|-------------------|----------------|
| ACC (Image 1) | 80                 | 59                | >2,0           |
| APC (Image 1) | 100                | 7                 | pas de seuil   |
| ACC (Image 2) | 66                 | 44                | >2,0           |
| APC (Image 2) | 99                 | 21                | pas de seuil   |

La méthode ACC n'est pas très précise. Cette méthode détecte moyennement les zones perturbées et elle est très sensible au bruit dans les images. Par conséquent, elle donne un taux de fausses alarmes très élevé. Par contre, l'APC produit une meilleure détection et offre un taux de fausses alarmes moins élevé. Le problème de l'ACC est l'utilisation de l'information spectrale de l'image, or, celle-ci est fortement affectée par le bruit. Le résultat de la méthode est donc fortement bruité. Contrairement à l'ACC, l'APC utilise le résultat de la classification de cette image ; cette opération permet de réduire le bruit. L'APC semble être la méthode qui offre la meilleure détection. Par ailleurs, il est possible d'améliorer le résultat de la classification utilisé par l'APC.



**Tableau 4.5: Résultats obtenus sur les données simulées(en %)**

| Données | Classification brute |            | Filtre majo. |            | ICM       |            |
|---------|----------------------|------------|--------------|------------|-----------|------------|
|         | détection            | F. alarmes | détection    | F. alarmes | détection | F. alarmes |
| Image 1 | 100                  | 7          | 100          | 6          | 100       | 4          |
| Image 2 | 99                   | 21         | 99           | 16         | 99        | 21         |

Le tableau 4.5 illustre le fait que les méthodes d'optimisation (ICM et filtre majoritaire) ne permettent pas forcément d'obtenir un meilleur résultat dans la procédure APC. Le taux de bonne détection est déjà très élevé (99 % et 100 %), ces méthodes ne l'améliorent pas. Par contre, le taux de fausses alarmes diminue légèrement pour l'image 1. De même, pour l'image 2, ce taux reste encore important. À la vue des résultats, le post-traitement de la classification améliore peu le résultat de l'APC. Cette opération ne semble pas nécessaire pour les données simulées, mais elle peut être importante pour les données réelles. En effet, les outils de post-traitement qui améliorent les classes seront moins évidentes et plus confuses sur les images réelles.

Les résultats de l'identification à partir du masque sont présentés dans le tableau 4.6.

**Tableau 4.6: Résultats de l'identification sur les images simulées (en %)**

| Images        | Classe 2 | Classe 6 | Classe 9 |
|---------------|----------|----------|----------|
| Image 1 (APC) | 99       | 75       | 100      |
| Image 2 (APC) | 99       | 70       | 100      |
| Image 1 (ACC) | 90       | 71       | 69       |
| Image 2 (ACC) | 67       | 45       | 62       |

Les problèmes rencontrés dans la première phase mènent à des erreurs dans l'identification des classes. Ainsi, la précision de l'identification est plus faible dans le cas de l'ACC que dans l'APC. L'APC semble fournir les meilleurs résultats. L'identification de la classe 2 et 9 est quasiment parfaite. Seule la classe 6 pose des problèmes sur les deux images. En réalité,

cette classe a des caractéristiques spectrales très proches d'autres classes dans la scène. La confusion spectrale entraîne donc une difficulté à identifier cette classe.

Le tableau 4.7 présente un des meilleurs résultats obtenus avec la base de règles. La même base de règles et les mêmes paramètres ont été appliqués sur les deux images. Dans cette partie, l'influence de ces paramètres n'est pas discutée. Deux problèmes apparaissaient avec la méthode classique : un taux de fausses alarmes élevé et une difficulté pour l'identification de la classe 6. L'approche avec la base de règles permet de réduire de façon considérable le taux de fausses alarmes. Pour l'image 1, le meilleur taux était de 4 %, obtenu avec la combinaison de l'APC et l'ICM. La base de règles permet d'éliminer les erreurs ( $<0,5$  %). Le même constat peut se faire pour l'image 2, où le taux de fausses alarmes était de 16 % avant la procédure modifiée. L'application de la base de règles donne un taux à 1 %. Dans les deux cas, la base de règles a permis de réduire considérablement le taux de fausses alarmes.

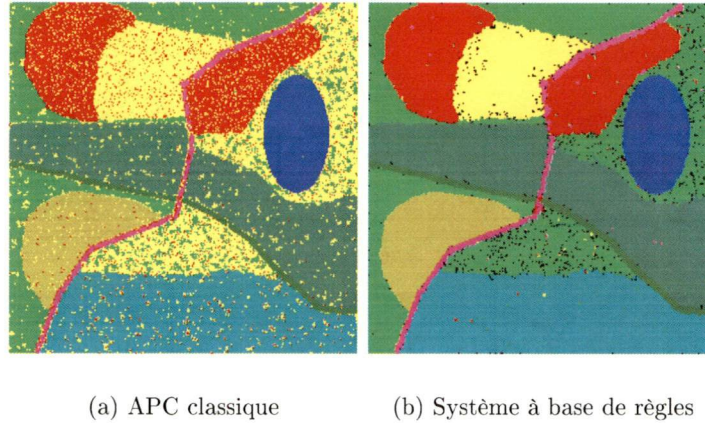
**Tableau 4.7: Résultats du système à base de règles (en %)**

| Données | Règles utilisées <sup>a</sup> | F. alarmes | Identification |          |          |       |
|---------|-------------------------------|------------|----------------|----------|----------|-------|
|         |                               |            | Classe 2       | Classe 6 | Classe 9 | Kappa |
| Image 1 | T + E + C                     | 0          | 100            | 98       | 100      | 99    |
| Image 2 | T + E + C                     | 1          | 99             | 94       | 100      | 94    |

<sup>a</sup>C = contextuelle E = sites d'entraînement T = transitions

En ce qui concerne l'identification, l'approche classique ne présentait pas de problèmes avec les classes 2 et 9. Ces classes étaient déterminées avec une précision respective de 99 % et 100 %. Cette précision est aussi obtenue avec la base de règles. Par contre, la classe 6 n'était pas très bien relevée par la méthode classique (image 1 : 75 % et image 2 : 70 %). Les règles permettent d'atteindre une précision de 98 % pour l'image 1 et 94 % pour l'image 2. Le système conserve une bonne précision sur l'image 2. L'image 1 ne présente pas réellement de difficultés pour le système, alors que l'APC traditionnelle montre des limitations sur les

deux images.



**Figure 4.7: Comparaison des différentes approches (image fortement bruitée)**

L'avantage du système à base de règles par rapport aux méthodes classiques est sa robustesse. En effet, une fois la base créée pour une image, celle-ci peut s'appliquer sans changement sur une autre image de la même scène. Le travail est alors conservé et peut être reproduit dans le temps pour la même scène, alors que les méthodes classiques nécessitent parfois de mettre en oeuvre un seuil de détection. Le seuil doit être redéfini pour chaque étude. Par ailleurs, bien que les images simulées ne présentent pas réellement de difficultés, les méthodes classiques n'offrent pas de bons résultats. Le système a prouvé qu'il pouvait améliorer largement les résultats obtenus par une approche classique.

Le système à base de règles nécessite la mise en place de plusieurs paramètres, notamment le facteur de certitude de l'information et des règles.

#### 4.3.1.3. Sensibilité aux facteurs de certitude

Le facteur de certitude permet de pondérer l'importance de chaque règle. Actuellement, l'estimation des poids n'est pas possible automatiquement. L'utilisateur est obligé de la réaliser. Ce

facteur détermine la confiance que l'utilisateur accorde à la règle dans la résolution du problème. La pondération des sources est un problème souvent rencontré par les méthodes de fusion d'informations et peut s'avérer difficile. Les auteurs abordent ce problème en définissant leur propre fonction de masse (Germain *et al.*, 2003; Allard, 2001). Dans le cas de la base de règles, l'utilisateur attribue lui-même la pondération pour chaque règle à l'aide du facteur de certitude. Il est donc important de savoir si les facteurs influencent de beaucoup la qualité du résultat.

Les tableaux 4.8 et 4.9 présentent quelques résultats obtenus. Les règles ont été pondérées de la manière suivante ; 0,4 signifie peu de confiance sur les règles et 1,0 très confiant. Pour l'image faiblement bruitée, le facteur intervient peu dans la précision du résultat final. Cette image présente peu de difficultés, c'est pourquoi en accordant plus d'importance à une information, le résultat varie peu.

**Tableau 4.8: Sensibilité aux facteurs de certitude pour l'image 1(en %)**

| Informations <sup>a</sup> |     |     | F. alarmes | Identification |          |          |
|---------------------------|-----|-----|------------|----------------|----------|----------|
| E                         | T   | C   |            | Classe 2       | Classe 6 | Classe 9 |
| 0,4                       | 0,4 | 1,0 | 0          | 100            | 98       | 100      |
| 0,4                       | 1,0 | 0,4 | 0          | 100            | 98       | 100      |
| 1,0                       | 0,4 | 0,4 | 0          | 99             | 98       | 100      |
| 1,0                       | 1,0 | 0,4 | 0          | 99             | 98       | 100      |
| 1,0                       | 0,4 | 1,0 | 0          | 100            | 97       | 100      |
| 0,4                       | 1,0 | 1,0 | 0          | 100            | 98       | 100      |

<sup>a</sup>C = contextuelle E = sites d'entraînement T = transitions

Par contre, l'image 2 permet de relever de faibles variations dans le résultat. Effectivement, le taux de fausses alarmes peut être de 1, 2 ou 3 % selon le poids. Même un taux de 3 % est meilleur que celui des approches classiques. De même, l'identification est peu affectée par une modification du facteur de certitude de l'information.



**Tableau 4.9: Sensibilité aux facteurs de certitude pour l'image 2(en %)**

| Informations <sup>a</sup> |     |     | F. alarmes | Identification |          |          |
|---------------------------|-----|-----|------------|----------------|----------|----------|
| E                         | T   | C   |            | Classe 2       | Classe 6 | Classe 9 |
| 0,4                       | 0,4 | 1,0 | 3          | 100            | 93       | 100      |
| 0,4                       | 1,0 | 0,4 | 1          | 99             | 94       | 100      |
| 1,0                       | 0,4 | 0,4 | 1          | 99             | 93       | 100      |
| 1,0                       | 1,0 | 0,4 | 1          | 98             | 94       | 100      |
| 1,0                       | 0,4 | 1,0 | 2          | 99             | 94       | 100      |
| 0,4                       | 1,0 | 1,0 | 1          | 99             | 94       | 100      |

<sup>a</sup>C = contextuelle E = sites d'entraînement T = transitions

Il apparaît que le facteur de certitude peut faiblement influencer la qualité du résultat. Même si les variations sont faibles, les résultats varient selon la combinaison choisie et ceux-ci ne sont pas constants. Cette faible variation peut s'expliquer aussi par le fait que les images simulées sont moins complexes que les données réelles. Une étude sur les données réelles est donc nécessaire pour observer si une variation plus importante peut apparaître.

#### 4.3.1.4. Pertinence des règles

Comme la base de règles comprend de nombreuses règles, la question est de savoir si toutes les règles élaborées sont nécessaires. En effet, lorsque des règles sont éliminées, certains objets ne pourront plus être identifiés. Les tableaux 4.10 et 4.11 montrent quelques résultats obtenus avec différents choix de règles.

L'influence du type de règles sur la précision est plus évidente sur l'image 2 (tableau 4.11). En effet, l'utilisation uniquement du contexte spatial ou encore des règles sur les transitions n'offre pas les meilleurs résultats ; par contre celles sur les sites d'entraînement permettent d'atteindre de bons taux. La combinaison de ces dernières règles avec un des deux autres types produit un meilleur résultat. Par exemple, le taux de fausses alarmes pour l'image fortement bruitée (image 2) (C : 8 % et T : 9 %) diminue avec la combinaison des règles (E + C : 2 % et E + T : 1 %). Les règles sont basées sur des caractéristiques différentes de l'objet.

**Tableau 4.10: Sensibilité aux règles pour l'image 1(en %)**

| Règles utilisées <sup>a</sup> | F. alarmes | Identification |          |          |
|-------------------------------|------------|----------------|----------|----------|
|                               |            | Classe 2       | Classe 6 | Classe 9 |
| C                             | 1          | 100            | 97       | 100      |
| T                             | 5          | 100            | 98       | 100      |
| E                             | 0          | 99             | 98       | 100      |
| C + T                         | 1          | 100            | 98       | 100      |
| E + C                         | 0          | 100            | 97       | 100      |
| E + T                         | 0          | 99             | 98       | 100      |
| C + E + T                     | 0          | 100            | 98       | 100      |

<sup>a</sup>C = contextuelle E = sites d'entraînement T = transitions

Leur combinaison permet de dépasser les limites de l'utilisation d'un seul type de règles. La combinaison permet aussi d'obtenir une identification des classes plus précise. Effectivement, l'utilisation des sites d'entraînement uniquement n'offre pas la meilleure précision pour la classe 6 (93 %). Par contre, l'ajout des règles sur les transitions (T) permet d'obtenir une meilleure précision (94 %). Pour les deux images, l'utilisation de toutes les règles permet alors d'obtenir une légère amélioration de l'identification et une réduction considérable des erreurs.

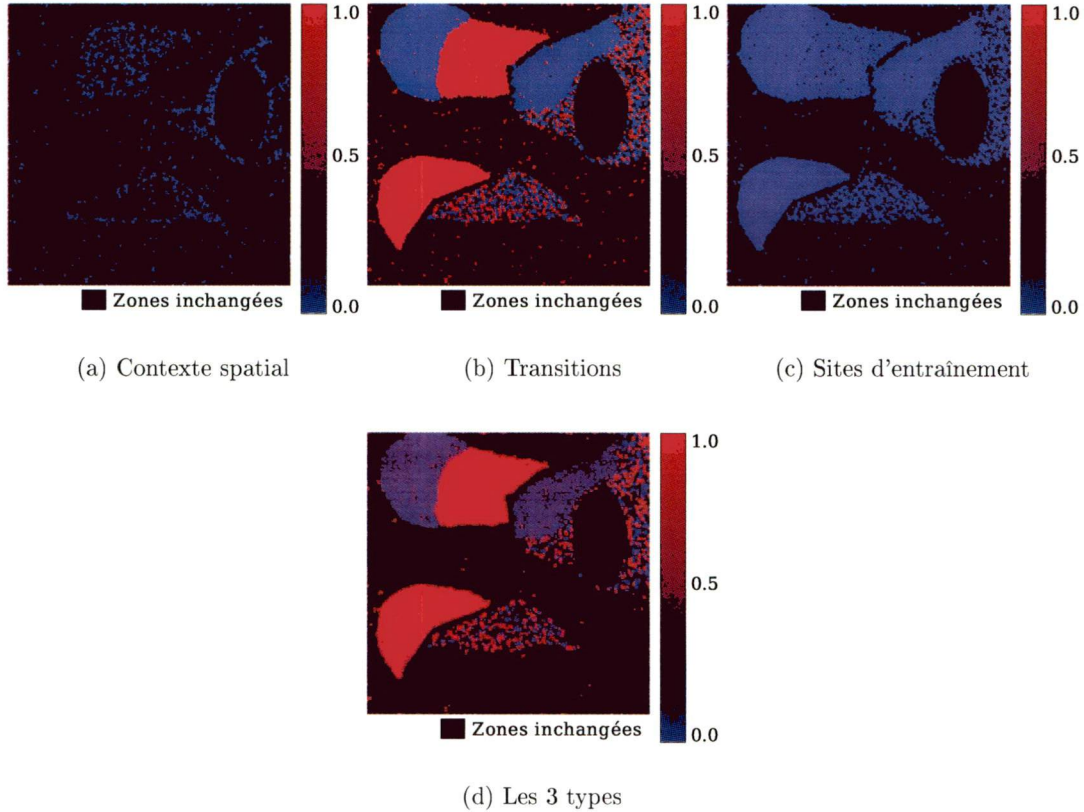
**Tableau 4.11: Sensibilité aux règles pour l'image 2(en %)**

| Règles utilisées <sup>a</sup> | F. | Identification |          |          |
|-------------------------------|----|----------------|----------|----------|
|                               |    | Classe 2       | Classe 6 | Classe 9 |
| C                             | 8  | 99             | 93       | 100      |
| T                             | 9  | 99             | 94       | 100      |
| E                             | 2  | 99             | 93       | 100      |
| C + T                         | 7  | 99             | 94       | 100      |
| E + C                         | 2  | 99             | 93       | 100      |
| E + T                         | 1  | 98             | 94       | 100      |
| C + E + T                     | 1  | 99             | 94       | 100      |

<sup>a</sup>C = contextuelle E = sites d'entraînement T = transitions

Par surcroît, la combinaison des règles améliore aussi la certitude sur l'identification des zones changées. La figure 4.8 montre le fait que certaines sources d'information identifient avec une faible certitude les régions. Par contre, en combinant plusieurs règles, les régions

peuvent être identifiées plus adéquatement.



**Figure 4.8: Influence des règles sur le résultat (image fortement bruitée)**

Les règles sont basées sur des sources d'information complètement différentes. D'une part, les sources peuvent s'accorder pour certaines régions, ce qui renforce l'identification. Cela se traduit par une augmentation de la certitude sur l'identification. D'autre part, une source peut identifier une région alors que l'autre ne peut statuer sur la nature. Ainsi, la complémentarité des règles permet d'identifier un plus grand nombre d'objets.

Ces faits ont déjà été observés avec les méthodes d'analyse d'image basées sur la fusion. La base de règles agit comme une méthode de fusion. La combinaison des règles est équivalente

à une fusion de sources d'information. Dans ce cas, le système expert est comparable à une méthode de fusion experte.

Le temps n'est pas un critère pris en compte dans l'étude, mais selon les règles utilisées, le temps de raisonnement peut être très différent. Les règles sur le contexte et les sites d'entraînement peuvent augmenter considérablement le temps de raisonnement. En effet, ce type de règles fait intervenir de nombreux faits, alors que les règles sur les transitions sont assez simples. La figure 4.10 illustre bien le fait que lorsque la règle sur les sites d'entraînement est utilisée, le temps augmente énormément.

Selon Friedman (Friedman-Hill, 2003), le temps de raisonnement dépend fortement du nombre de faits par règle et du nombre de règles dans la base. La figure 4.10 illustre bien cette constatation.

#### 4.3.1.5. Approche par pixel ou approche orientée objet ?

L'approche orientée objet est préférée dans cette étude, parce qu'elle reproduit le processus d'interprétation visuelle. En outre, elle permet l'élaboration de règles proches de l'interprétation humaine. Dans le cas des images simulées, les règles sont assez simples et n'utilisent pas réellement de critères d'interprétation. L'analyse traditionnelle de l'image, autrement dit pixel par pixel, est donc possible pour ce type de données. Le système à base de règles a été testé dans le cadre d'une approche par pixel. Dans ce cas, le contexte spatial ne correspond plus aux objets voisins, mais aux huit pixels voisins.

La figure 4.11 présente les meilleurs résultats de l'approche par pixel sur les deux images.



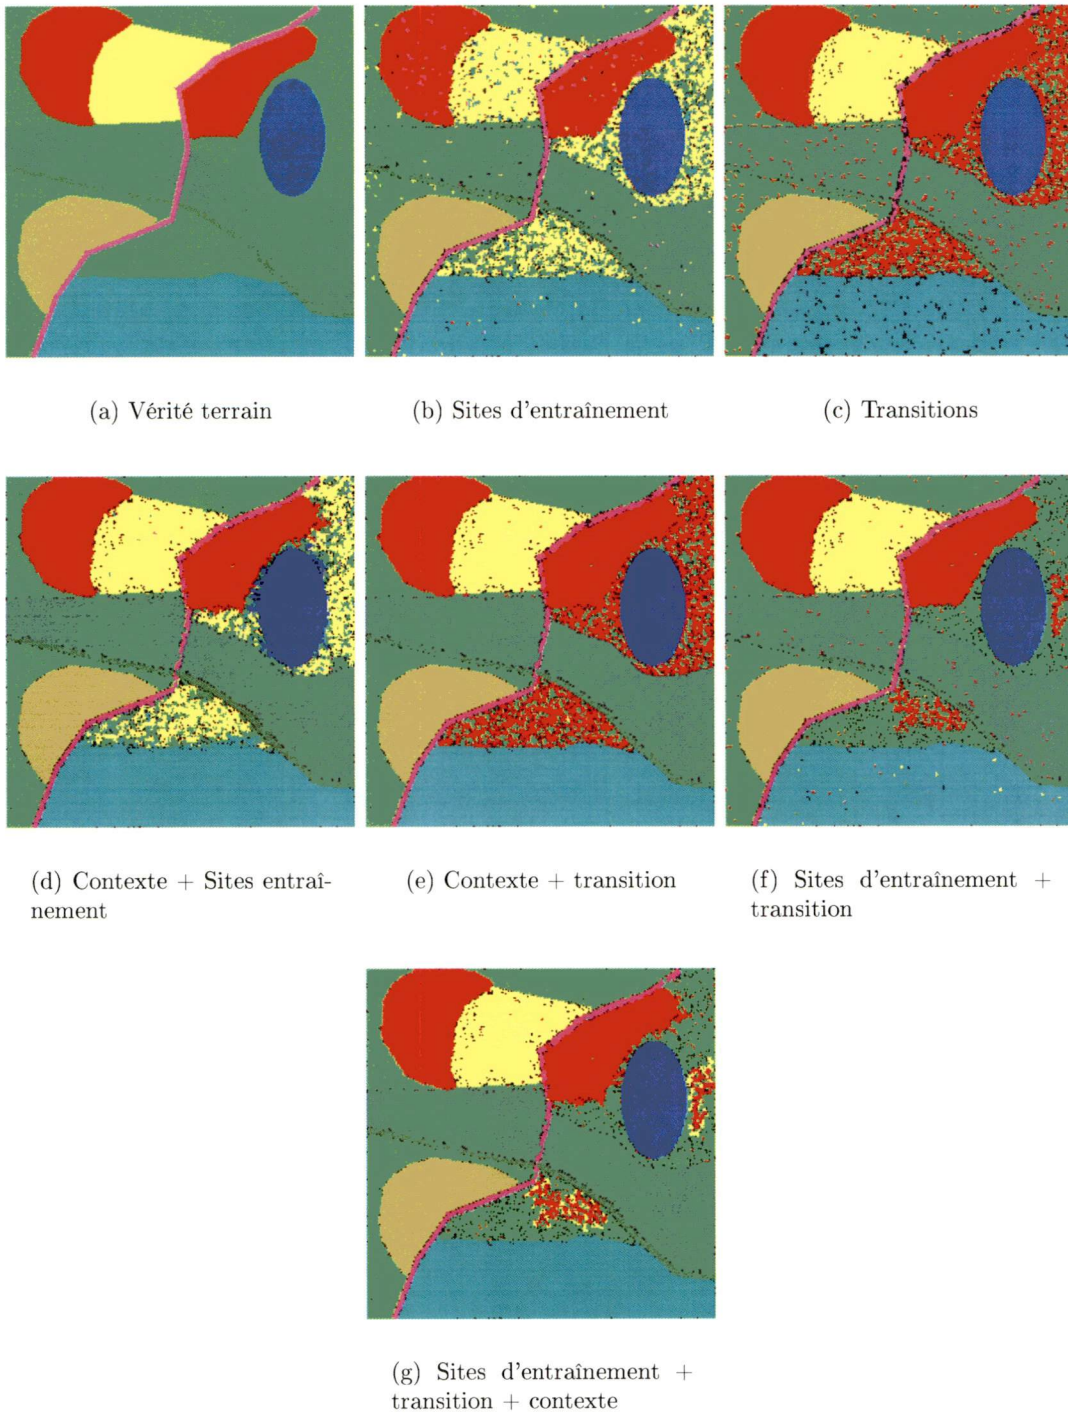


Figure 4.9: Influence des règles sur le résultat (image fortement bruitée)





Figure 4.10: Temps de raisonnement en fonction des règles



(a) Image 1

(b) Image 2

Figure 4.11: Approche par pixel

L'analyse pixel par pixel de l'image offre aussi des résultats intéressants. L'identification des régions est aussi précise que l'approche par objet, cependant le taux de fausses alarmes est encore élevé (image 1 : 3 % et image 2 : 6 %). L'approche par pixel fournit des résultats équi-

valents aux approches classiques qui sont aussi basées sur une analyse par pixel de l'image.

Par ailleurs, l'approche par objet analyse beaucoup moins d'entités que l'approche par pixel. Pour l'image 1, cette approche a permis l'analyse de 20 452 objets en 21 minutes, alors que l'approche par objet a pris 6 minutes pour 3813 objets. L'expérience a été effectuée sur un *Pentium* III 800 MHz.

#### 4.3.1.6. Conclusion partielle sur les données simulées

Les résultats obtenus avec les données simulées ont montré la force de l'approche par rapport aux méthodes conventionnelles. En effet, les approches classiques ne produisent pas de très bons résultats, pourtant, la scène simulée est assez simple et ne présente pas réellement de complexité. Une des limitations des méthodes classiques est l'utilisation uniquement de l'information spectrale. Quant à la base de règles, elle intègre sous forme de règles cette même information mais aussi des informations relatives à la scène, comme l'occupation du sol. La combinaison de toutes ces informations permet d'obtenir des résultats supérieurs aux méthodes conventionnelles.

D'un autre côté, les résultats du système à base de règles dépendent de la qualité de la base. Plusieurs paramètres interviennent dans la procédure. Le facteur de certitude permet de pondérer chaque règle de la base. Il est apparu que cette pondération pouvait faiblement influencer le taux de fausses alarmes et le taux de bonne identification des régions. Par ailleurs, la base de règles doit être complète. Le manque de certaines règles peut aussi influencer l'identification mais aussi le degré de certitude de l'identification. L'idéal est d'avoir des règles sur plusieurs critères de l'objet, car si certains critères permettent l'identification d'une région, d'autres peuvent confirmer ou infirmer cette identification.



### 4.3.2. Résultats sur les données réelles à moyenne résolution

Les résultats sur les données simulées ont montré que l'approche par un système à base de règles est une avenue pour la détection du changement. La prochaine étape est d'évaluer le système sur des données réelles.

Dans un premier temps, plusieurs approches classiques ont été pratiquées sur l'ensemble de données à moyenne résolution. Ces résultats sont comparés avec ceux du système à base de règles. L'approche a montré quelques sensibilités par rapport à certains paramètres pour les données simulées. Les analyses tentent de vérifier si l'approche proposée présente les mêmes sensibilités pour les données réelles.

#### 4.3.2.1. La base de règles

Les travaux de (Kauth et Thomas, 1976; Coppin et Bauer, 1996; Roy *et al.*, 1996; Patterson et Yool, 1998; Coppin *et al.*, 2001; Hayes et Sader, 2001; Lorena *et al.*, 2002; Civco *et al.*, 2002) et les critères supplémentaires, notamment les indices de végétation permettent d'élaborer plus de règles pour les données à moyenne résolution spatiale que pour les données simulées.

Dans les paragraphes suivants, nous parlons plus de type de règles. Pour faciliter l'analyse nous avons regroupé les règles en 4 classes (contexte spatial C, sites d'entraînement S, indicateurs I, transitions T). L'énoncé des règles est présenté ci-dessous :

- un objet proche d'un site d'entraînement est possiblement de même nature que ce site.  
Cette règle est valide si les caractéristiques spectrales de l'objet sont proches de celles du site (S) ;
- un objet peut avoir la même classe qu'un de ces voisins (C) ;
- une zone changée peut avoir un accès à proximité (C) ;



- les classes forestières peuvent changer en une coupe (T) ;
- une ancienne coupe peut devenir une zone en régénération naturelle (T) ;
- une ancienne zone en régénération peut devenir une zone en régénération naturelle (stade 2) (T) ;
- les autres changements de classes sont considérés comme des erreurs. Dans ce cas, l'ancienne classe est privilégiée (T) ;
- les régions, dont la taille est faible et la classe est différente du voisinage, peuvent être un bruit (I) ;
- un changement a pu se produire si une chute d'indice de végétation (ndvi, arvi, greenness) est observée (I) ;
- une ancienne zone forestière ne peut pas avoir un indice "brightness" important (I) ;
- une route a une compacité très élevée (I) ;
- une zone changée a possiblement une faible compacité (proche de 1)(I).

Après une optimisation de l'écriture des règles, le nombre de règles à été réduit à 29 règles pour la moyenne résolution (voir annexe I). Celles-ci concernent uniquement les 3 classes de changement. La base de règles serait plus conséquente si des règles pour chaque classe de la carte étaient élaborées.

#### 4.3.2.2. Comparaison avec l'approche classique

##### a) La détection classique du changement

La différence d'images et l'ACP ont été appliquées aux images de Juillet 1988 et 1999. Les deux autres méthodes ont utilisé la carte de 1989. Le tableau 4.12 présente les résultats obtenus avec les différentes méthodes.

Le premier problème constaté dans la détection est la détermination du seuil pour l'élimination du bruit. Certaines méthodes nécessitent même la mise en place de plusieurs seuils,


**Tableau 4.12: Résultats de la détection sur les données réelles (en %)**

| Méthode            | Bonne<br>détection | Fausse<br>alarmes | Seuils choisis                                  |
|--------------------|--------------------|-------------------|---|
| Différence d'image | 90                 | 7                 | $<-0,05 - >0,2$                                 |
| ACP                | 79                 | 7                 | composantes 2 : $>1,6$ ; 3 : $<-1,6$ 4 : $>2,1$ |
| ACC                | 53                 | 6                 | $>12$   |
| APC                | 95                 | 44                | pas de seuil                                    |

notamment l'ACP. Les seuils sont choisis par dichotomie de manière à obtenir un taux de fausses alarmes faible. La figure 4.12 illustre l'influence du seuil sur la précision de la détection pour la méthode ACC. Il apparaît ici que les deux taux diminuent en fonction du seuil. Le problème est de choisir un seuil pour obtenir un taux de détection assez fort, mais aussi un taux de fausses alarmes faible. Dans le cas présent, le taux de détection diminue moins fortement que le taux de fausses alarmes. En choisissant un seuil à 12, la méthode donne un taux de fausses alarmes identique aux autres méthodes (7 %). En raison de ce choix, le taux de détection est faible (53 %). De même, il est aussi possible de choisir un taux de détection proche de la méthode APC (95 %), ce qui donne alors un taux de fausses alarmes de l'ordre de 80 %.

Ceci illustre bien la problématique pour ce type de méthode. Dans le cas d'une méthode nécessitant l'élaboration de plusieurs seuils, la difficulté est répétée pour chaque seuil. La détermination du seuil n'est pas évidente et la qualité du résultat dépend du choix de l'utilisateur. Ce problème n'apparaît pas avec l'APC, puisqu'aucun seuil n'est nécessaire.

Les méthodes basées sur le seuillage offrent de très bons résultats au niveau du taux de fausses alarmes (6 - 7 %). Effectivement, l'APC donne un taux très élevé (44 %), mais elle permet une meilleure détection (95 %). Les zones détectées par l'APC correspondent à des changements de classes, or le changement peut être uniquement dû à une mauvaise classification du pixel. La confusion peut se produire entre deux classes végétales (ex : marais - forêt peu dense). Ces deux classes ne correspondent aucunement aux zones de perturbation,



**Figure 4.12: Influence du choix du seuil sur les taux (méthode ACC)**

mais selon cette méthode, elles seront considérées comme possiblement changées.

La plupart des méthodes présentent des problèmes en bordure des régions. Les zones changées apparaissent notamment sur les rives des lacs. Par ailleurs, la route est fortement détectée alors qu'elle n'a pas changée entre les deux acquisitions. Que ce soit les bordures des régions ou des régions de petite taille, ces zones sont essentiellement composées de pixels mixtes. Les méthodes montrent des difficultés sur ce type de pixel.

L'étape de détection est très importante, car les erreurs obtenues lors de la création du masque se propagent dans l'identification.

#### b) L'identification classique du changement

Les statistiques des différentes identifications sont présentées dans la figure 4.14. Toutes les méthodes ont bien détectées les zones de coupe (tableau 4.13). Généralement, ce type de perturbation est bien visible sur les images satellitaires. La précision est de 94 à 98 %



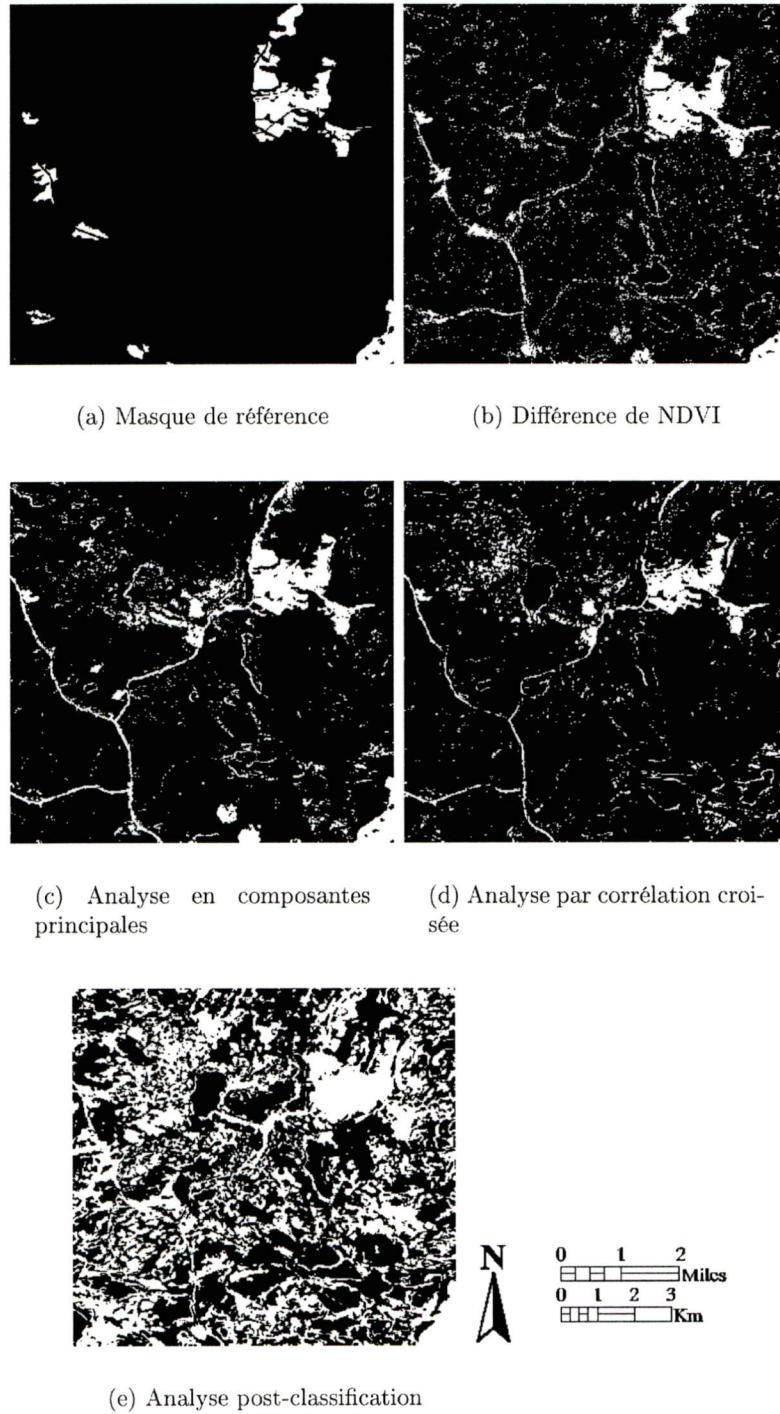
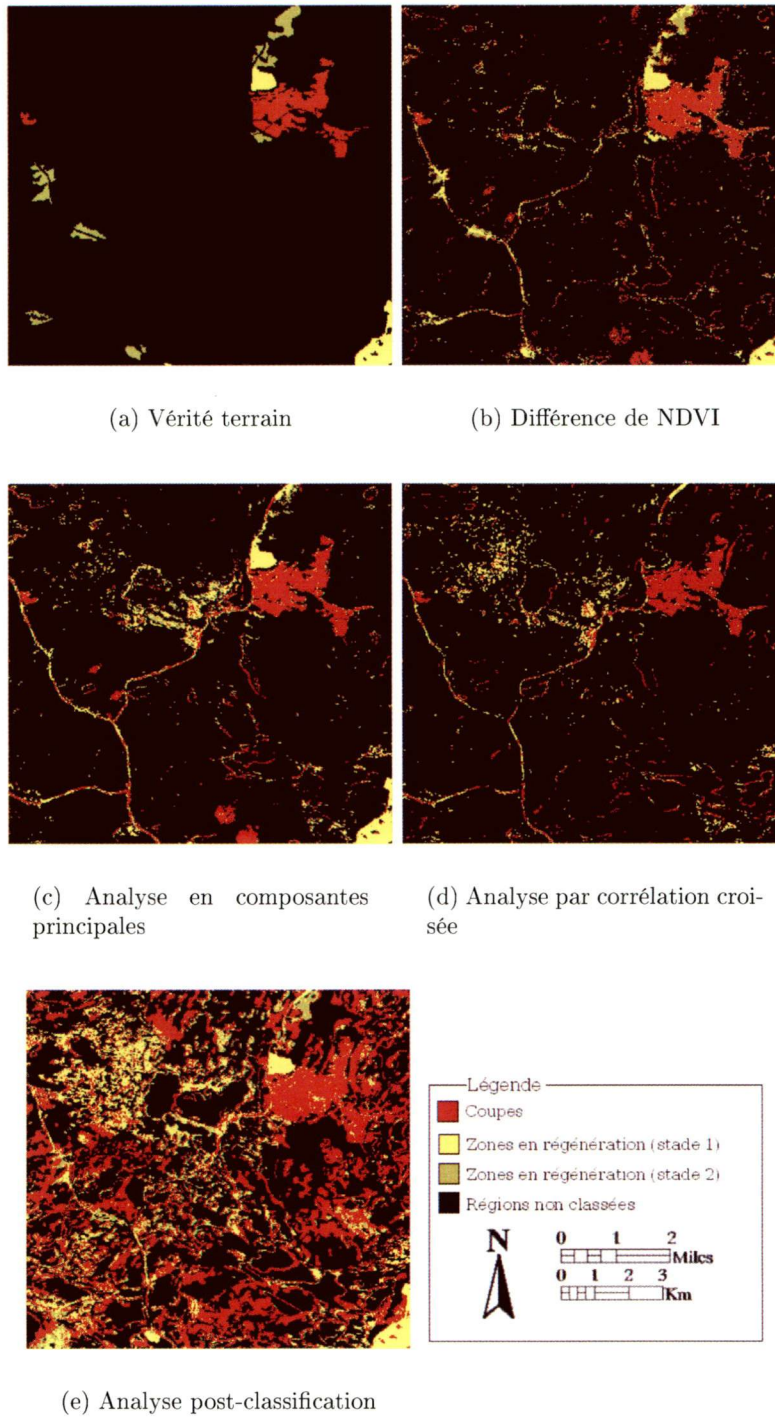


Figure 4.13: Résultats des différentes méthodes de détection du changement





**Figure 4.14: Résultats de l'identification des zones changées**

selon la méthode. En revanche, la précision est plus faible pour les zones en régénération naturelle. Effectivement, les classes *regen 1* et *regen 2* peuvent être relevées respectivement avec 87 % et 41 % de précision. L'ACC ne permet pas de relever la phénologie de la végétation, c'est pourquoi les valeurs sont vraiment faibles pour les zones de régénération naturelle.

**Tableau 4.13: Résultats de l'identification (en %)**

| Méthode            | Coupes | Regen 1 | Regen 2 |
|--------------------|--------|---------|---------|
| Différence d'image | 98     | 84      | 36      |
| ACP                | 98     | 87      | 15      |
| ACC                | 94     | 12      | 3       |
| APC                | 98     | 87      | 41      |

L'APC permet la meilleure identification des zones perturbées. Le seul problème est que cette méthode a détecté de nombreuses mauvaises zones. Bien que la précision de l'identification soit bonne, la qualité du résultat est malheureusement affectée par les erreurs relevées dans la première phase. Pour cette étude, la différence d'indices semble être la méthode la plus efficace. En effet, la masque comporte peu d'erreur et l'identification des perturbations est assez bonne. Dans le cas d'une mise à jour d'une carte existante, il est nécessaire d'utiliser l'APC.

La méthode APC offre un meilleur taux d'identification pour les régions. La réduction des fausses alarmes permettrait d'améliorer considérablement les résultats de cette approche. Puisqu'un résultat de classification est utilisé dans la procédure, il est intéressant de vérifier, comme dans le cas des images simulées, si un post-traitement augmente la précision.

#### c) La réduction des erreurs dans l'APC

Pour les images simulées, l'optimisation du résultat de classification améliorerait légèrement la détection dans l'APC. Les résultats obtenus avec les données réelles confirment cette consta-

tation (tableau 4.14).

**Tableau 4.14: Résultats obtenus avec la classification sur les données réelles (en %)**

| Données    | Classification brute |            | Filtre majo. |            | ICM       |            |
|------------|----------------------|------------|--------------|------------|-----------|------------|
|            | détection            | F. alarmes | détection    | F. alarmes | détection | F. alarmes |
| Landsat 99 | 95                   | 44         | 95           | 40         | 95        | 41         |

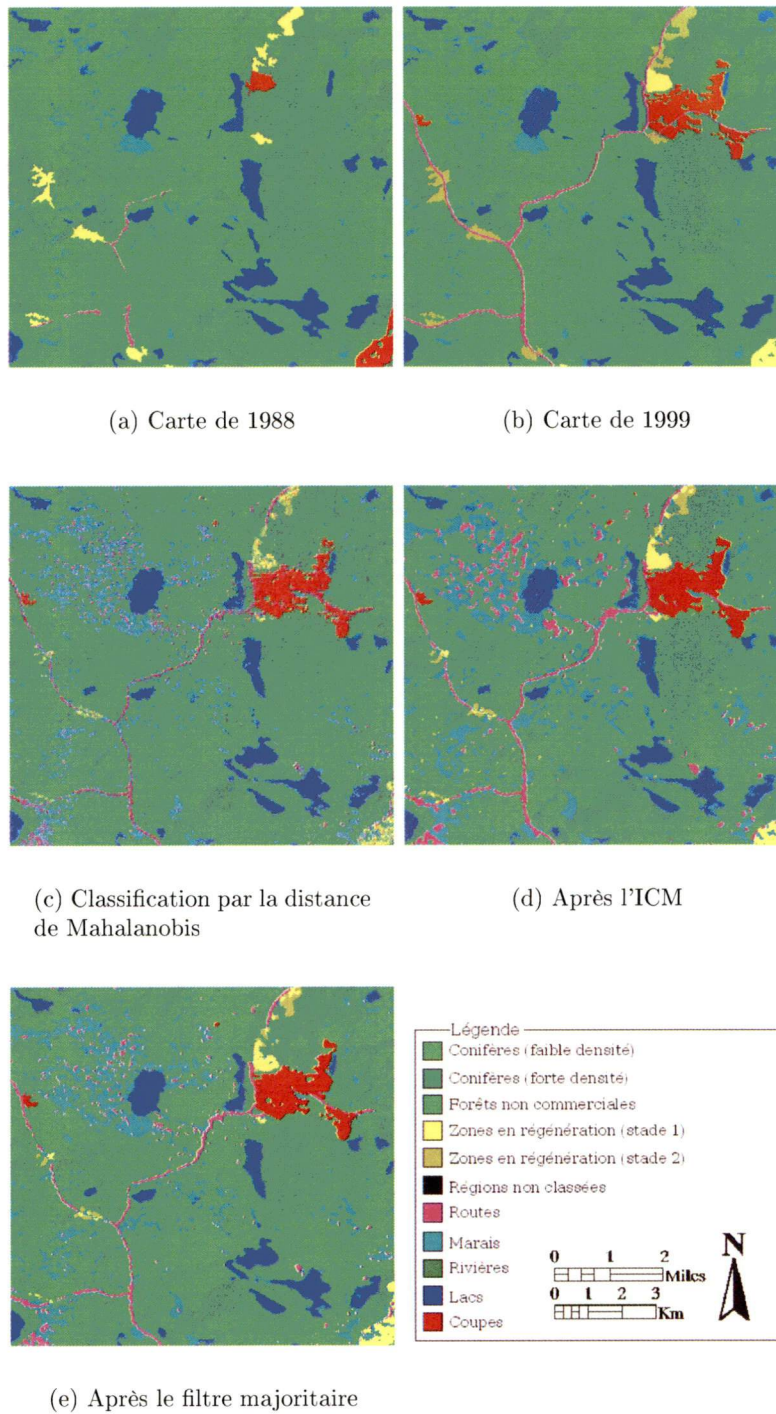
La classification brute permet d'obtenir un taux de 95 %, qui n'est pas amélioré par les techniques d'optimisation. Par contre, le taux de fausses alarmes diminue légèrement avec ces méthodes (réduction de 3 à 4 %). Cette réduction n'est pas suffisante pour conclure qu'un traitement post-classification permettra d'améliorer la qualité du masque.

Les méthodes d'optimisation ne permettent pas d'améliorer considérablement les résultats de la détection du changement. Les résultats obtenus comportent encore de nombreuses erreurs. Le contexte spatial utilisé dans l'ICM et le filtre majoritaire est certainement très important mais il n'est pas suffisant pour réduire les erreurs de la procédure APC. Il est nécessaire de compléter cette information par d'autres sources d'information ; c'est pourquoi la base de connaissances peut être intéressante.

#### d) Résultat avec la base de règles

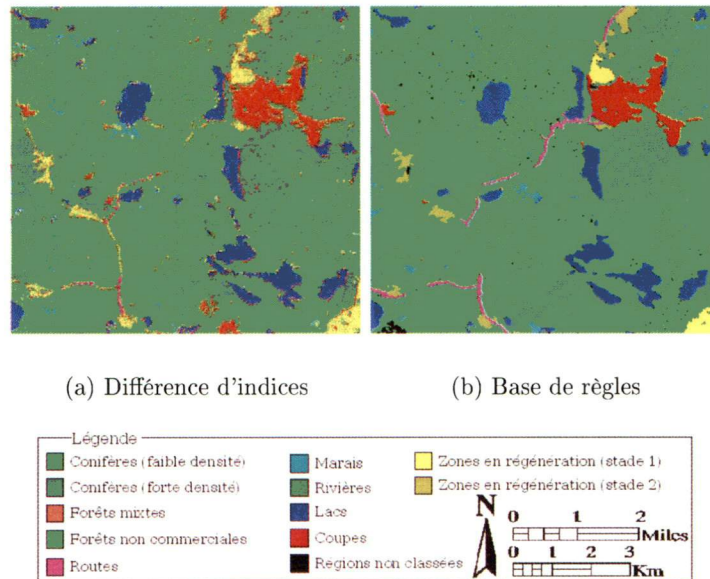
La figure 4.16 permet de comparer le résultat obtenu par la meilleure des approches classiques et celui obtenu à l'aide de la base de règles. Premièrement, la base de règles a permis de réduire toutes les erreurs causées par l'approche classique. Ce taux est maintenant de 2 % alors que pour la méthode de la différence d'indices, il était de 7 %. Par ailleurs, cette réduction est plus importante par rapport à l'analyse post-classification classique (40 %).





**Figure 4.15: Ensemble de données pour APC**





**Figure 4.16: Mise à jour de la carte de 1989**

Le système permet une meilleure discrimination de ces zones perturbées. La précision pour la classe *regen1* passe de 87 % à 90 % et pour la classe *regen2*, de 41 % à 63 %. Quant aux coupes, le taux demeure à 98 %. La base de règles conserve donc la même précision pour les coupes ; par contre, elle permet d'améliorer considérablement les résultats sur les zones difficiles à distinguer, telles que les zones en régénération naturelle.

**Tableau 4.15: Résultats obtenus avec le système à base de règles (en %)**

| Données      | Informations utilisées | F. alarmes | Coupes | Régén. 1 | Régén. 2 |
|--------------|------------------------|------------|--------|----------|----------|
| LANDSAT 1999 | Toutes les règles      | 2          | 98     | 90       | 63       |

Certains paramètres de l'approche pouvaient faire varier le résultat du système pour les données simulées. La question est de savoir si les données réelles confirment les observations faites dans la première partie.

#### 4.3.2.3. Pertinence des règles

Il est important de vérifier que toutes les règles interviennent utilement dans la procédure. Ainsi, l'absence d'un type de règles pourrait entraîner une baisse de la précision de l'approche.

Les résultats obtenus sur les données simulées ont montré une sensibilité à la composition de la base. En effet, certaines régions ne pouvaient pas être identifiées par des règles. Cette sensibilité est plus flagrante sur les données réelles. De nombreuses parties de la scène demeurent non identifiées (en noir sur les figure 4.17 a,b,c et d). Par ailleurs, lorsqu'un seul type de règles est utilisé, l'identification peut être mauvaise. Effectivement, aucun autre type de règles n'est présent pour corriger cette possible erreur. Le tableau 4.16 montre que si on utilise uniquement les règles sur le contexte spatial ou les sites d'entraînement, les résultats sont faibles en ce qui concerne l'identification. Par contre, ils réduisent nettement les fausses alarmes. À l'opposé, les règles sur les indicateurs et l'occupation du sol (transitions) fournissent une bonne identification, mais un mauvais taux de fausses alarmes. Chaque règle réagit différemment. Les résultats montrent bien qu'elles n'agissent pas sur les mêmes parties de l'image. Les zones non identifiées ne sont pas situées aux mêmes endroits.

L'association des règles sur le voisinage et les sites d'entraînement permet de conserver le même taux de fausses alarmes, par contre les régions sont mieux identifiées. L'ajout d'un troisième type de règles, l'occupation du sol, maintient le taux de fausses alarmes, mais l'identification est nettement améliorée. Les coupes passent de 71 % à 92 %, la classe *regen 1* de 84 à 91 %. Le plus fort gain vient de la dernière classe, avec un passage de 26 à 70 %.

Finalement, la combinaison de toutes les règles fournit un très bon résultat. Le taux de fausses alarmes est faible, les coupes sont mieux détectées. Malheureusement, la classe *régén 2* perd de la précision. Cette classe est assez difficile à identifier, elle se confond grandement avec les autres classes végétales. L'ajout des indices de végétation dans le processus

ne permet pas de discriminer plus de régions de cette classe, mais simplement confirmer les déductions faites par les autres règles.

**Tableau 4.16: Résultats du système avec les données réelles (en %)**

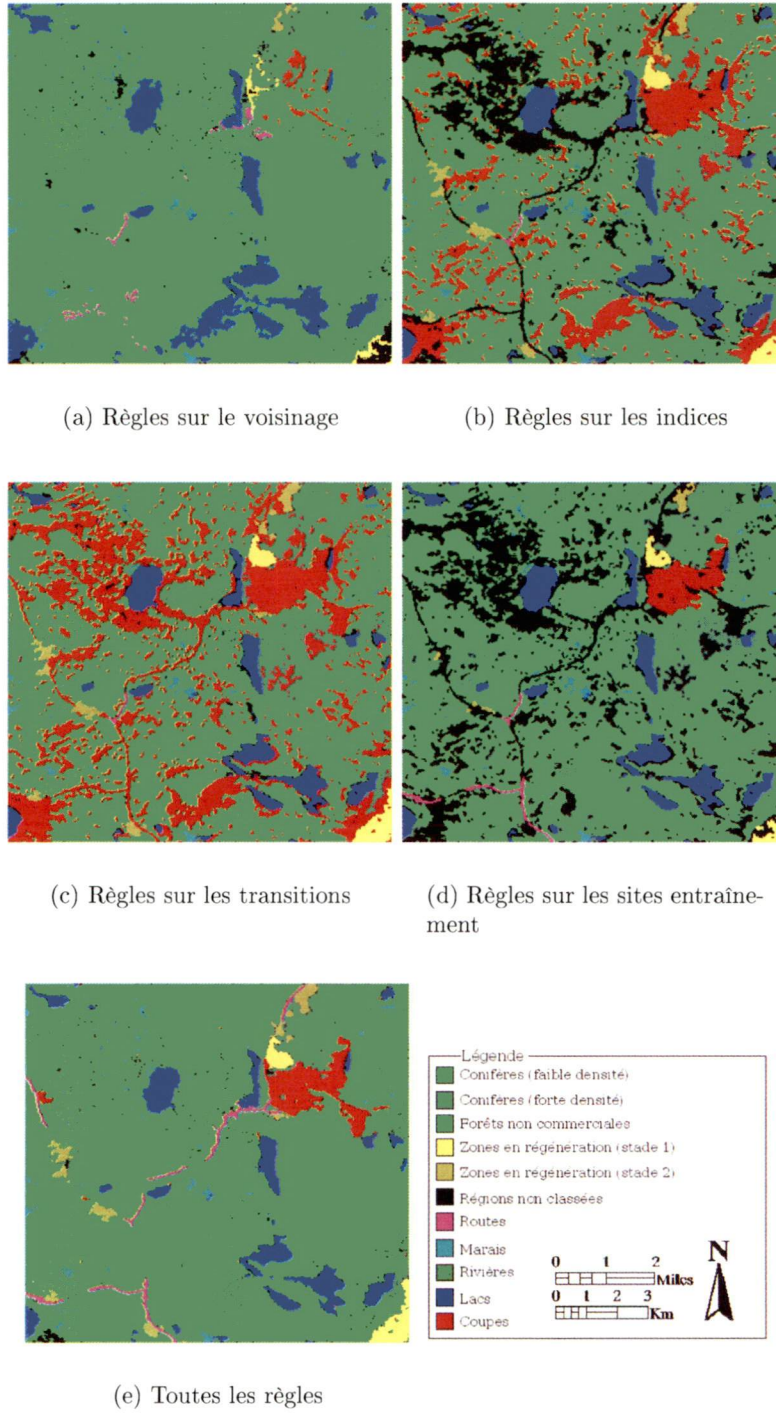
| Règles utilisées <sup>a</sup> | Fausses alarmes | Identification |          |          |
|-------------------------------|-----------------|----------------|----------|----------|
|                               |                 | Coupes         | Régén. 1 | Régén. 2 |
| C                             | 1               | 2              | 19       | 5        |
| I                             | 12              | 98             | 87       | 62       |
| T                             | 22              | 99             | 87       | 62       |
| S                             | 1               | 79             | 67       | 21       |
| S + C                         | 1               | 71             | 84       | 26       |
| S + C + T                     | 2               | 92             | 91       | 70       |
| S + I + C + T                 | 1               | 98             | 90       | 63       |

<sup>a</sup>S = sites d'entraînement, I = indicateurs, C = contexte spatial, T = Transitions

Cette étude montre que toutes les règles de la base sont nécessaires. En outre, l'association de toutes les règles permet d'améliorer la certitude sur l'identification des régions. Les règles sur les indicateurs donnent un degré de certitude assez élevé (de 0,5 à 0,8). Les règles sur les transitions identifient beaucoup de régions, mais la certitude des régions est plus faible (0,2 à 0,5). La certitude pour les régions est moyenne pour les règles sur les sites d'entraînement et très faible lorsque le contexte spatial est utilisé. La confiance sur l'identification des régions changées se situe autour de 0,8 lorsque toutes les règles sont combinées (figure 4.18).

#### 4.3.2.4. L'importance du facteur de certitude

Le système à base de règles fait face au problème de l'estimation du facteur de certitude de chaque règle. L'approche était sensible à ce paramètre pour les données simulées. Les variations dans les résultats étaient de l'ordre de 1 %. Dans le cas présent, ces variations sont plus importantes (4 % pour les coupes et *regen 1* et 29 % pour *regen 2*).



**Figure 4.17: Influence des règles sur le résultat**



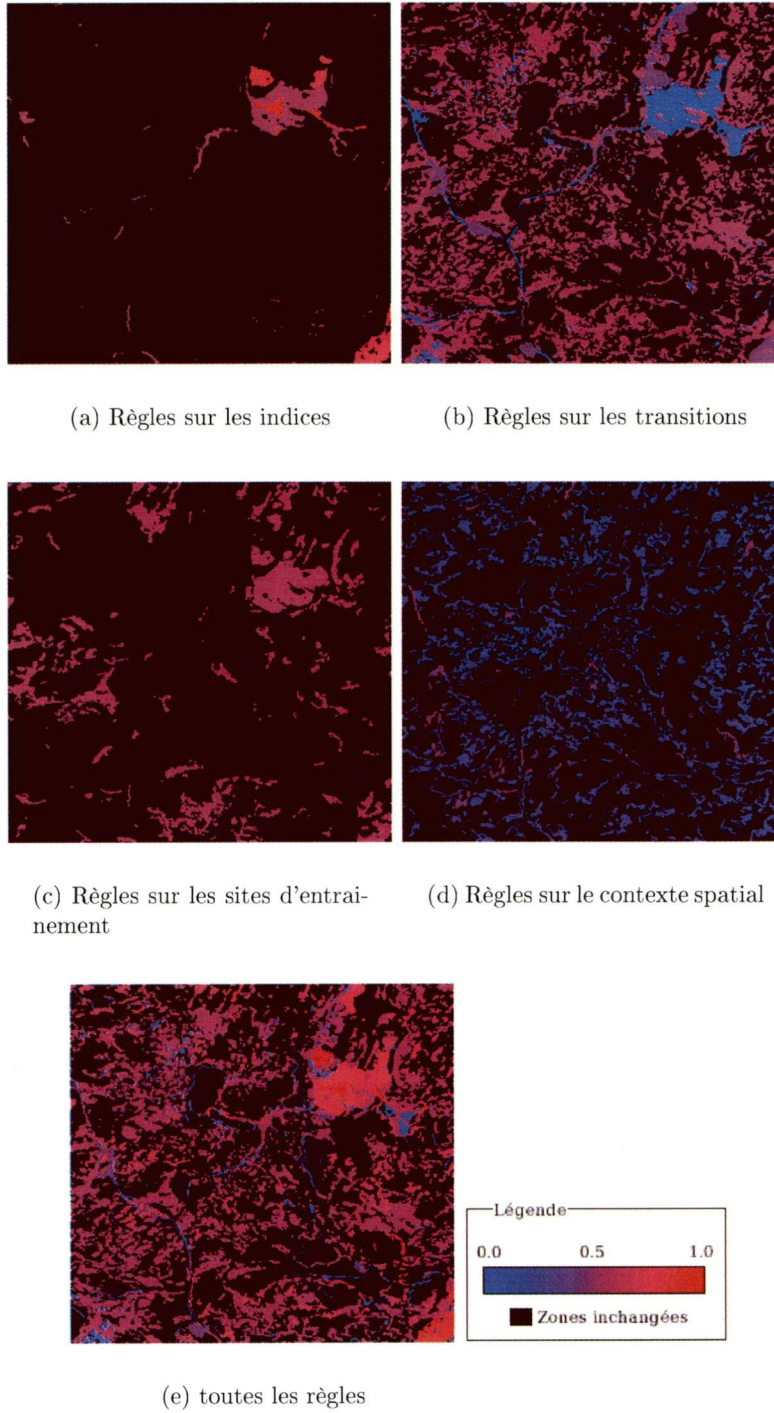


Figure 4.18: Confiance sur l'identification

Le facteur de certitude permet d'accorder plus d'importance à une règle. Dans le tableau 4.16, on a remarqué que le voisinage ne permet pas d'obtenir de bons résultats, par contre il réduit fortement le taux de fausses alarmes. Il serait donc nécessaire d'accorder moins d'importance à ce type de règles. Le facteur de certitude des règles pourrait être contrôlé par d'autres règles (meta-règles). Cette approche permettrait donc d'ajuster ce facteur en fonction de divers paramètres. Le tableau 4.17 montre que lorsque l'on donne trop d'importance à ce type de règles le résultat n'est pas satisfaisant. Par contre, la réduction du facteur réduit fortement l'influence de la règle et, en même temps, améliore le résultat. L'attribution d'un même facteur de certitude à toutes les règles n'est pas une bonne solution. Il n'est pas possible d'établir des lois pour choisir le poids des règles. Le principe est d'accorder plus de crédit à une règle pertinente et moins à une règle non significative. L'estimation des poids est délicate et nécessite plusieurs tests. Le problème apparaît aussi pour les méthodes de fusion multi-source. La détermination des poids dépend souvent de l'appréciation de l'utilisateur.

**Tableau 4.17: Sensibilité au facteur de certitude (en %)**

| Importance de l'info <sup>a</sup> |     |     |     | Fausses alarmes | Précision |         |         |
|-----------------------------------|-----|-----|-----|-----------------|-----------|---------|---------|
| S                                 | V   | T   | I   |                 | Coupes    | Regen 1 | Regen 2 |
| 0,8                               | 0,8 | 0,4 | 0,8 | 1               | 95        | 88      | 36      |
| 0,8                               | 0,8 | 0,8 | 0,4 | 1               | 94        | 86      | 34      |
| 0,4                               | 0,8 | 0,8 | 0,8 | 1               | 94        | 86      | 34      |
| 0,8                               | 0,4 | 0,8 | 0,8 | 1               | 98        | 90      | 63      |
| 0,4                               | 0,4 | 0,8 | 0,8 | 1               | 98        | 90      | 63      |
| 0,8                               | 0,8 | 0,4 | 0,4 | 1               | 94        | 88      | 36      |
| 0,8                               | 0,8 | 0,8 | 0,8 | 1               | 94        | 86      | 34      |

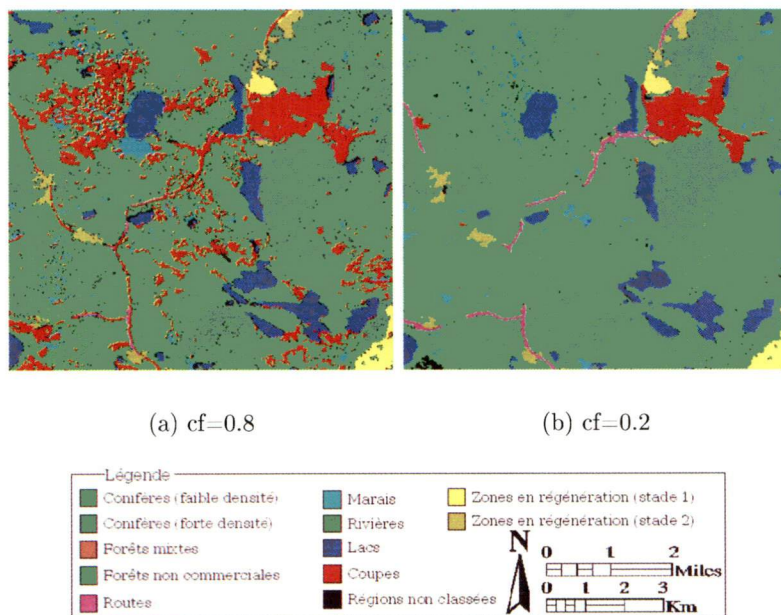
<sup>a</sup>S = sites d'entraînement, C = contexte spatial, T = transitions, I = indicateurs

Pour illustrer l'importance du facteur de certitude, nous proposons l'exemple suivant ; une règle incertaine est introduite dans la base. En réalité, cette règle est fausse.

L'énoncé de la règle est :

- si le ndvi est fort et qu'il s'agit d'une ancienne forêt, alors c'est peut-être une coupe forestière.

Il est clair que si cette règle a autant d'importance que les autres règles, le résultat sera faussé. La figure 4.19 représente l'impact du facteur de certitude de cette règle sur le résultat final. Une forte certitude sur cette règle perturbe le résultat. Les autres règles ne peuvent pas compenser l'erreur. Par contre, un plus faible facteur permet aux autres règles d'infirmar cette conclusion.



**Figure 4.19: Influence d'une mauvaise règle**

Le facteur ne doit pas être établi au hasard, puisqu'il intervient grandement dans la procédure. Il est préférable de le réduire pour les règles que l'on pense incertaines. Cette pondération dépendra beaucoup de la connaissance de l'expert et pourra aussi affecter la précision du résultat. Ce problème apparaît aussi dans la réalité, puisque les interprétations d'une même scène faites par deux interprètes ne seront pas les mêmes.

#### 4.3.2.5. Conservation de la connaissance

L'intérêt des systèmes à base de règles est la conservation de la connaissance. Autrement dit, une base élaborée à partir de constatations pour un site d'étude devrait pouvoir être appliquée sur une autre image du même site. Dans ce cas, le travail réalisé peut servir à nouveau pour des applications futures, notamment pour une autre mise à jour.

Les résultats obtenus sur les images LANDSAT de 2000 et 2001 montrent que la base peut être appliquée dans le futur à d'autres données Landsat (tableau 4.18). Les coupes sont détectées avec une précision de 92 % et 89 %, l'application de la base de règles permettait de trouver jusqu'à 98 % des coupes sur l'image de 1999. Une adaptation de certaines règles serait peut-être nécessaire pour atteindre cette précision. De même, les sites en régénération (stade 1) sont détectés avec une plus faible précision dans les images de 2000 et 2001. En revanche, les sites en régénération (stade 2) sont relevés avec une précision identique, et même meilleure sur l'image de 2000. Le système donne des résultats assez satisfaisants si l'on tient compte du fait qu'aucune modification n'a été nécessaire pour appliquer la base sur les nouvelles images.

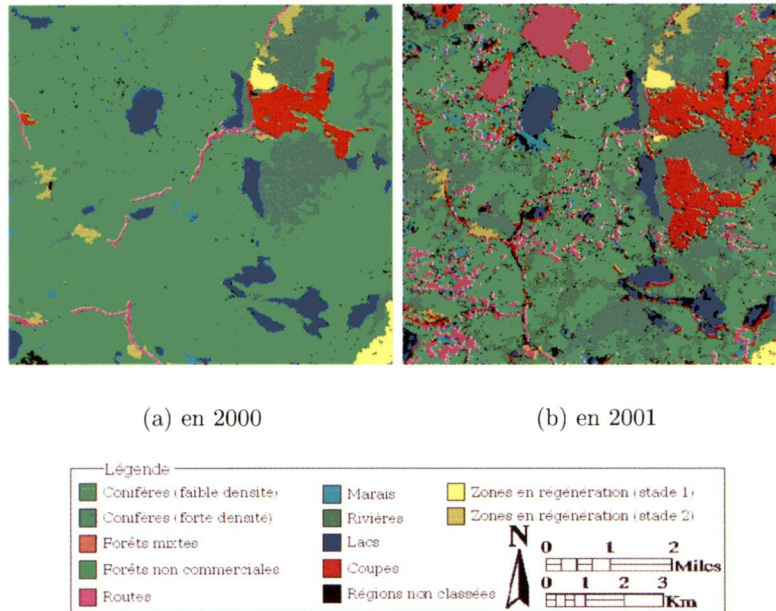
**Tableau 4.18: Résultats de l'approche modifiée pour les images LANDSAT 2000 et 2001 (en %)**

| Données    | Fausses alarmes | Coupes | Regen1 | Regen2 |
|------------|-----------------|--------|--------|--------|
| Landsat 00 | 3               | 92     | 87     | 68     |
| Landsat 01 | 4               | 89     | 88     | 63     |

Des nuages sont présents sur la scène de 2001, le système n'a pas classifié ce nuage dans une des classes de perturbation connues. Une analyse traditionnelle aurait certainement classée cette zone couverte par des nuages en une zone perturbée. En général, pour éviter ce problème avec une méthode traditionnelle, un masque est réalisé pour enlever les nuages. Dans notre cas, cette opération n'a pas été nécessaire. Les cartes finales sont présentées dans les



figures 4.20 a) et b).



**Figure 4.20: Résultats de l'application de la base**

Le système à base de règles permet donc de réduire le travail d'interprétation si une base existe déjà pour la scène étudiée. Les résultats peuvent être améliorés par l'interprète, si celui-ci se focalise uniquement sur les régions mal identifiées par le système. En s'aidant de la carte de certitude, l'interprète peut effectuer une mise à jour plus rapidement.

L'APC classique ne permet pas efficacement de relever et d'identifier les changements de la zone. Les résultats de la méthode dépendent énormément de la qualité de la classification. Malheureusement, la confusion entre les classes pour ce site est importante, ce qui rend quasiment impossible une mise à jour automatique et régulière pour ce site d'étude.

Les résultats du tableau 4.19 confirment que l'approche classique offre une moins bonne précision dans l'ensemble. Si elle permet d'obtenir des résultats satisfaisants sur l'identifica-

**Tableau 4.19: Résultats de l'APC classique pour les images LANDSAT 2000 et 2001 (en %)**

| Données    | Fausses alarmes | Coupes | Regen1 | Regen2 |
|------------|-----------------|--------|--------|--------|
| Landsat 00 | 56              | 91     | 68     | 49     |
| Landsat 01 | 46              | 92     | 87     | 41     |

tion des coupes, la carte finale est toujours influencer par le taux de fausses alarmes élevé. Les résultats de l'APC demeure pour les images 1999, 2000 et 2001 en-dessous de ceux du système à base de règles.

#### 4.3.2.6. Base d'exemples ou base de règles ?

Plusieurs tests ont été effectués avec le réseau de neurones et l'arbre de décision. Le tableau 4.20 récapitule quelques résultats obtenus avec les deux méthodes. Les méthodes obtiennent des résultats assez satisfaisants dans l'ensemble, notamment une réduction importante du bruit (2 % de fausses alarmes). En effet, ces méthodes identifient bien les coupes (95-96 %). Cette classe ne pose pas de problème non plus pour le système à base de règles. Ce dernier obtenait 98 % pour cette classe. La classe *regen 1* est moins précise (80-81 %) alors que la base de règles obtenait 90%. La dernière classe est plus précise avec les systèmes à apprentissage automatique (68 % au lieu de 63 %).

Un des problèmes rencontrés dans l'utilisation du réseau de neurones est la détermination d'une structure adéquate. Pour obtenir les meilleurs résultats, une seule couche cachée avec 8 neurones a été nécessaire. Par ailleurs, le taux d'apprentissage a été fixé à 0,4. Une fois le réseau déterminé, les résultats sont comparables à la base de règles. L'arbre de décision est certainement plus facile à mettre en oeuvre, puisque l'apprentissage nécessite peu d'interventions de l'utilisateur. En conservant les paramètres de l'arbre par défaut, celui-ci offre les mêmes résultats que le réseau de neurones. La détermination des paramètres du réseau ou de l'arbre peut poser des difficultés et risque d'influencer grandement les performances de ces

méthodes. De ce point de vue, le système à base de règles n'est pas plus commode à utiliser puisqu'il nécessite aussi l'élaboration de paramètres comme le facteur de certitude des règles.

**Tableau 4.20: Résultats obtenus avec les autres méthodes intelligentes sur l'image LANDSAT de 1999 (en %)**

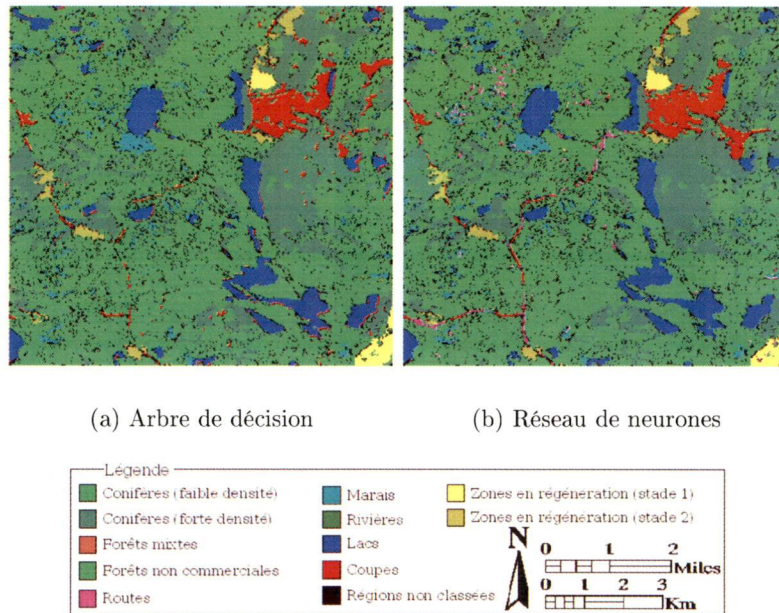
| Méthodes           | Informations utilisées <sup>a</sup> | Coupes | Régén. 1 | Régén. 2 |
|--------------------|-------------------------------------|--------|----------|----------|
| Arbre de décision  | E + AC                              | 81     | 81       | 68       |
| Arbre de décision  | S + I + AC                          | 95     | 81       | 68       |
| Réseau de neurones | S + I + AC                          | 96     | 81       | 68       |
| Réseau de neurones | S + T + AC                          | 95     | 80       | 68       |
| Réseau de neurones | S + T + E + AC                      | 95     | 81       | 68       |
| Réseau de neurones | S + T + E + G + AC                  | 96     | 81       | 68       |

<sup>a</sup>AC = ancienne carte, E = environnement, T = texture, S = bandes spectrales, I = indicateurs, G = géométrie

L'arbre de décision et le réseau de neurones permettent aussi l'intégration de paramètres supplémentaires par rapport à la base de règles, comme la texture. Cette information peut être introduite dans la base de règles mais il est difficile d'établir des règles robustes sur les paramètres de texture. De plus, si l'on introduit ce paramètre dans l'une des deux méthodes, il ne conduit pas forcément à une meilleure précision. L'arbre de décision ne considère pas ce paramètre comme étant pertinent pour établir la structure de l'arbre. En fait, l'arbre optimal est obtenu avec l'information des bandes spectrales, des indices de végétation et des transitions, les mêmes informations utilisées par le système à base de règles. Contrairement à l'arbre, le réseau n'élimine pas les informations négligeables pour l'identification ; il quantifie simplement l'information à son entrée.

En observant les résultats obtenus avec les méthodes à apprentissage automatique, il apparaît qu'elles peuvent être une alternative, cependant moins précise que la base de règles. En réalité la qualité du résultat dépendra beaucoup du choix des exemples. La figure 4.22 représente l'influence du nombre d'exemples sur la précision de la méthode. La figure a été obtenue grâce à l'identification de 900 échantillons sur l'image LANDSAT 1999. Si l'on uti-






**Figure 4.21: Résultats des autres approches intelligentes sur l'image de 1999**

lise 300 échantillons pour l'entraînement, les deux méthodes semblent déjà pouvoir identifier la totalité des exemples avec une précision supérieure à 95 %. Après 300 exemples, l'ajout d'exemples pour l'apprentissage améliore faiblement la précision.

Le problème des méthodes à apprentissage par l'exemple est la détermination d'un bon ensemble d'apprentissage. Il doit être complet pour représenter suffisamment de cas de figures des régions à identifier. Ainsi, si la base d'exemples représente bien les cas rencontrés sur la scène, ces méthodes peuvent être très précises. Le problème est de trouver suffisamment d'exemples dans une scène. Pour l'approche orientée objet, ces exemples sont des régions. La taille de la scène ne permet pas forcément de trouver suffisamment d'exemples pour chaque objet à identifier. Ce problème est moins important avec une approche par pixel.

Des tests ont été effectués pour vérifier l'utilisation de l'arbre de décision et du réseau de neurones pour une future mise à jour. Le principe est de vérifier si le travail réalisé à une

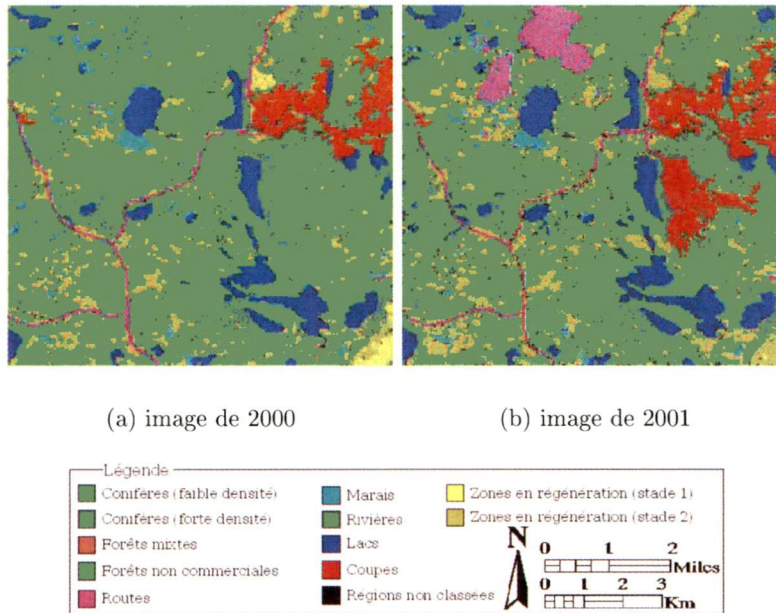




**Figure 4.22: Précision en fonction du nombre d'exemples**

date donnée peut s'appliquer à une autre date. Les résultats obtenus pour le site d'étude sont peu probants. En effet, un réseau de neurones ou un arbre de décision bien entraîné sur l'image de 1999 ne permet pas de ressortir les zones perturbées sur l'image de 2000 et 2001. Les méthodes sont trop spécifiques au site d'étude en 1999. Les nouvelles régions à identifier dans les images de 2000 et 2001 ont certainement des caractéristiques différentes de celles utilisées pour l'entraînement. Il est donc nécessaire d'effectuer un entraînement sur plusieurs années pour obtenir des méthodes robustes. En complétant la base d'exemples avec des régions de l'image de 2000, le réseau de neurones fournit des résultats légèrement meilleurs sur l'image de 2001 (figure 4.23).

Ayant plus d'exemples pour sa phase d'apprentissage, le réseau ne reconnaît pas mieux les régions de la nouvelle image de 2001. La méthode ne fournit pas de résultats suffisamment satisfaisants 4.21.



**Figure 4.23: Résultats du réseau de neurones**

**Tableau 4.21: Résultats obtenus avec le réseau de neurones (en %)**

| Méthodes           | Données      | Fausses alarmes | Coupes | Régén. 1 | Régén. 2 |
|--------------------|--------------|-----------------|--------|----------|----------|
| Réseau de neurones | LANDSAT 2000 | 15              | 91     | 70       | 91       |
| Réseau de neurones | LANDSAT 2001 | 20              | 90     | 2        | 93       |

Le taux de fausses alarmes demeure élevé sur les images de 2000 et 2001 (de 15 à 20 %). De même, l'arbre de décision ne permet pas une bonne identification des régions sur l'image de 2001. Les résultats montrent que les deux approches ne sont pas assez robustes. Les méthodes entraînées sur un ensemble de données ne peuvent pas être appliquées sur un ensemble plus récent sans un nouvel apprentissage. Autrement dit, les régions identifiées dans le passé ne sont pas suffisantes pour effectuer une mise à jour automatique. Malheureusement, les résultats ne sont pas aussi précis et constants que ceux obtenus avec la base de règles. La première explication de ce problème est une possible erreur dans les corrections des données. Les imperfections dans les corrections géométriques et radiométriques des images conduisent à une mauvaise identification des régions. Ce problème a déjà été soulevé par Coppin et Bauer (1994) pour les méthodes de détection du changement. Le système à base

de règles est moins affecté par le problème de la radiométrie, car il est basé sur l'analyse Post-Classification. Cette méthode est moins sensible au problème de correction radiométrique. La deuxième explication est que les méthodes sont trop spécifiques aux régions utilisées comme exemples. Pour surmonter ce dernier problème, il est important d'utiliser des critères pour l'identification des régions qui ne varient dans le temps.

### 4.3.3. Résultats préliminaires sur la très haute résolution

Le but de cette partie est de montrer une possible utilisation du système à base de règles sur la très haute résolution spatiale. L'étude n'est pas aussi complète que les deux précédentes, mais elle permet d'avoir une idée des potentialités de l'approche sur ce type de données. Actuellement, peu de méthodes de détection du changement utilisent les données à très haute résolution spatiale (Palandro *et al.*, 2003; Metternicht, 1999). Ce type de données est apparu récemment en télédétection et les méthodes d'analyse sont en cours de développement. Les méthodes cognitives sont peut-être une direction de recherche.

#### 4.3.3.1. Définition des règles

La base de règles est spécifique à ce type de données. Il est clair que les règles de la moyenne résolution ne peuvent plus s'appliquer ici, puisque la résolution est de l'ordre du mètre. Elles devront être adaptées au type de données. Les règles sur la forme sont plus importantes à cette résolution. Par ailleurs, l'image est acquise au mois de novembre, la neige recouvre des parties de l'image. La saison ne permet pas l'utilisation des indices de végétation.

Les règles de la base sont les suivantes :

- un objet proche d'un site d'entraînement est possiblement de même nature que ce site. Cette règle est valide si les caractéristiques spectrales de l'objet sont proches de celles du site ;

- un objet peut avoir la même classe qu'un de ces voisins ;
- une zone changée peut avoir un accès à proximité ;
- les classes forestières peuvent changer en une coupe ;
- une ancienne coupe peut devenir une zone en régénération naturelle ;
- une ancienne zone en régénération peut devenir une zone en régénération naturelle (stade 2) ;
- les autres changements de classes sont considérés comme des erreurs. Dans ce cas, l'ancienne classe est privilégiée (T) ;
- les régions, dont la taille est faible et la classe est différente du voisinage, peuvent être un bruit ;
- une zone couverte par la neige a une forte réflectance dans le visible et faible dans l'infrarouge ;
- une coupe et les zones en régénération naturelle peuvent être couvertes de neige ;
- les lacs et les routes peuvent être aussi couverts de neige ;
- l'ombre des zones forestières peut perturber un sol nu ;

#### 4.3.3.2. Résultats

Les résultats présentés dans cette partie concernent uniquement la comparaison du système à base de règles avec l'approche traditionnelle (APC). Ensuite, le système est évalué par rapport aux autres méthodes cognitives, l'arbre de décision et le réseau de neurones.

##### a) Approche APC traditionnelle

Les résultats obtenus avec l'APC ne sont pas satisfaisants. La méthode présentait déjà des limitations sur la moyenne résolution ; les résultats du tableau 4.22 prouvent qu'elle n'est pas adaptée à ce type d'image. La classification par la distance Mahalanobis de l'image Ikonos



n'est pas assez précise pour être utilisée dans la procédure. Le résultat présente énormément de confusion. Cette confusion se traduit par un taux élevé de fausses alarmes (61 %).

**Tableau 4.22: Résultats de l'approche APC (en %)**

| Données              | Bonne détection | Fausses alarmes | Coupes | Regen1 | Regen2 |
|----------------------|-----------------|-----------------|--------|--------|--------|
| Carte 89 + Ikonos 01 | 98              | 61              | 81     | 66     | 53     |

La neige permet effectivement de discriminer les coupes et les zones en régénération, cependant les lacs gelés et les routes peuvent aussi être couverts de neige. À une autre saison, cette confusion n'existerait pas. De même, les autres classes végétales ont plus ou moins une même réponse spectrale.

Un autre problème peut aussi expliquer les résultats. La carte de 1989 a été utilisée comme carte de référence. Malheureusement, les données sont à des résolutions différentes. Bien que les données aient été corrigées géométriquement avec une bonne précision, la superposition n'est peut être pas parfaite.

b) L'approche modifiée avec un système intelligent

Les erreurs relevées précédemment sont en partie corrigées par les différentes méthodes. Les trois méthodes permettent de réduire considérablement le taux de fausses alarmes. Celui-ci se situe encore à 10 % pour le système expert et 15 % pour les autres méthodes (tableau 4.23).

**Tableau 4.23: Résultats des différentes méthodes cognitives (en %)**

| Méthodes           | Fausses alarmes | Coupes | Regen1 | Regen2 |
|--------------------|-----------------|--------|--------|--------|
| Réseau de neurones | 15              | 76     | 60     | 58     |
| Arbre de décision  | 15              | 80     | 63     | 57     |
| Système expert     | 10              | 93     | 92     | 66     |

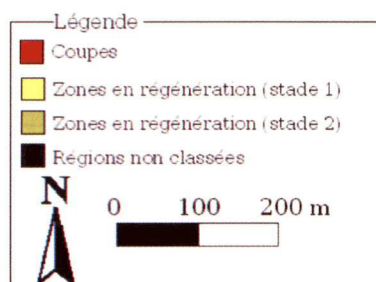
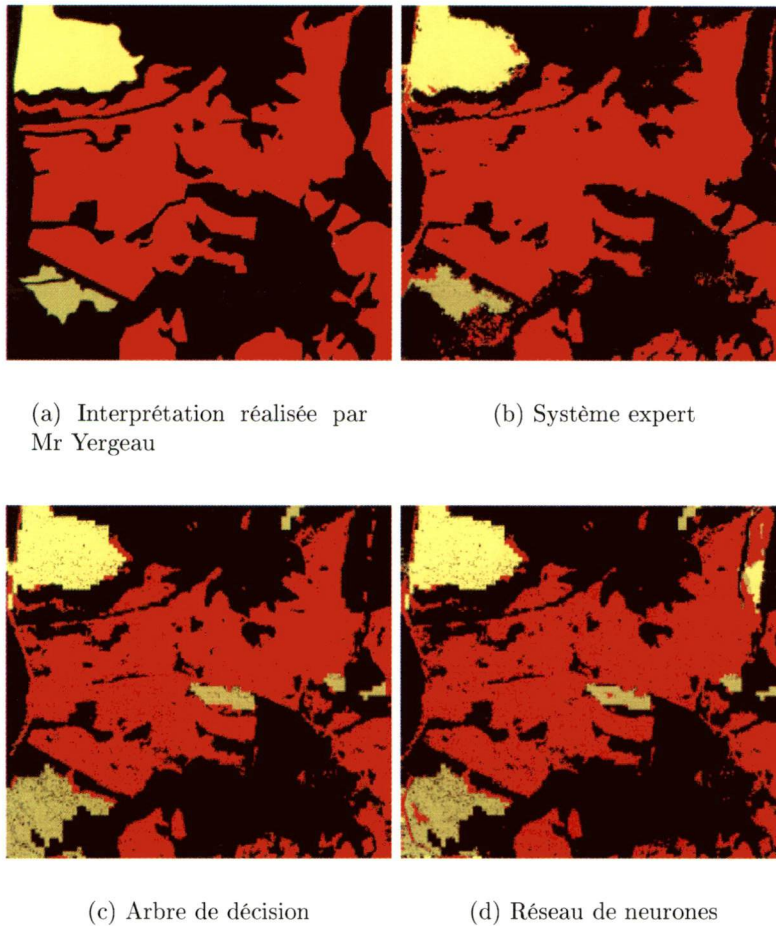
En ce qui concerne l'identification, le système à base de règles produit un résultat plus précis que les autres méthodes. Ces dernières ont des résultats du même ordre de grandeur. Les méthodes utilisent en fait la même base d'exemples. Le système à base de règles utilise plus ou moins la même information mais intègre aussi des informations spécifiques à la scène. Par ailleurs, il intègre différemment le contexte de l'objet.

Les figures 4.24 (b,c et d) illustrent les sorties de chaque méthode. Les méthodes cognitives associées à l'APC semblent être une solution intéressante pour l'utilisation des images Ikonos en détection du changement. À première vue, le système à base de règles obtient les meilleurs résultats.

#### 4.4. Conclusion partielle

Les différentes études menées dans ce chapitre ont pu montrer que plusieurs paramètres influencent les résultats de notre approche. Premièrement, la base de règles doit être assez fournie. L'idéal est d'avoir des règles sur plusieurs paramètres de l'objet. Le manque de certaines règles peut entraîner une baisse de la précision. Deuxièmement, le facteur de certitude des règles doit être bien estimé. L'étude a montré qu'il permet de réduire l'influence d'une règle incertaine dans le résultat final. La combinaison des facteurs de chaque règle permet d'établir le degré de certitude que le système accorde à l'identification. Les études prouvent qu'il est vraiment nécessaire de bien établir les règles et de peser l'importance de chacune des sources d'information. Il est difficile de réaliser cela automatiquement et c'est pour cela que de nombreux tests sont nécessaires. La base de règles et ses paramètres une fois établis, le système peut être appliqué pour un autre travail sur la même zone. Les règles sont alors conservées pour une autre analyse.

Si l'utilisateur ne désire pas utiliser cette approche, il peut alors utiliser les méthodes à apprentissage par l'exemple. Il suffit d'identifier des régions connues sur la scène et les méthodes



**Figure 4.24: Comparaison des méthodes cognitives sur Ikonos**

peuvent alors identifier chaque région de l'image. La précision est assez bonne si l'on a suffisamment d'exemples. En effet, ce type de méthode dépend de la représentativité de la base

d'exemples.

En général, les systèmes intelligents répondent bien aux exigences de l'identification des zones perturbées. Elles permettent de dépasser les méthodes conventionnelles utilisées dans ces procédures. Les méthodes conventionnelles d'analyse d'image ne permettent pas d'obtenir des résultats satisfaisants pour être utilisées dans une mise à jour.



## 5. Conclusions et recommandations

### 5.1. Recherche effectuée

Le travail réalisé dans cette étude est une approche novatrice dans la détection et l'identification des changements. La méthode propose de résoudre simultanément deux problèmes : les nombreuses fausses alarmes et la mauvaise reconnaissance des zones changées. Actuellement, les solutions proposées par la littérature ne sont pas suffisamment précises pour une mise à jour de carte. Les méthodes classiques nécessitent encore l'intervention de l'utilisateur dans plusieurs étapes de la procédure. D'une part, il doit éliminer les erreurs en élaborant un seuil et d'autre part, il doit souvent réaliser l'identification visuelle des régions. L'approche proposée dans ce travail permet de réduire le travail de l'interprète en lui proposant une base de connaissances adaptée à son site d'étude. Le système analyse la scène et fournit une identification de chaque région. Le système procure la carte de certitude de son analyse, ce qui permet à l'interprète de se focaliser sur les régions mal identifiées par le système (par exemple avec une certitude inférieure à 0,5). L'approche a été testée sur des images à moyenne et très haute résolution spatiale. Muni d'une base de connaissances adéquate pour son travail, le système délivre un résultat plus précis que les méthodes classiques de détection du changement. L'étude a montré que les méthodes qui utilisent uniquement l'information provenant de l'image ne produisent pas les meilleurs résultats. La combinaison de l'information issue des images et de la connaissance spécifique à l'application permet de mieux identifier les régions présentes dans une scène. La première hypothèse est donc vérifiée.

L'association d'une méthode conventionnelle et d'un système intelligent semble être une solution prometteuse. Cette approche réduit énormément le temps d'analyse du système, car celui-ci se concentre sur les zones mal déterminées par la méthode conventionnelle. De plus, la base de connaissances est plus facile à élaborer lorsque les règles sont destinées à quelques régions de la scène. Les premiers systèmes à base de règles ont souvent déçu parce qu'ils

tentaient de répondre à un problème trop complexe. Les règles étaient quelques fois difficiles à créer et le nombre important de règles produisait des systèmes très lents. Bien que le temps n'ait pas été pris en compte dans ce travail, le système est assez rapide. L'image Ikonos a été analysée par le système en 30 secondes sur un *Pentium 4* à 1,5 GHz. Cette image était composée de 4183 régions qui ont nécessité 27320 faits et 58585 règles activées. Un autre avantage du système est la possibilité de partage de la base de connaissances. Un interprète peut alors bénéficier du travail effectué par un autre interprète.

Le système à base de règles offre souvent de meilleurs résultats que les autres méthodes cognitives. Les approches n'utilisent pas les mêmes informations. La différence majeure est la connaissance relative à l'application (connaissance spécifique) utilisée par le système expert. Les autres méthodes cognitives utilisent uniquement les critères de région pour l'identification. Cette différence est plus flagrante sur la très haute résolution spatiale. Un autre problème des méthodes à apprentissage par l'exemple est la représentativité des exemples. Il est souvent difficile de définir suffisamment d'exemples pour une petite scène. Dans ce cas, le système à base de règles semble plus robuste, puisque son cheminement sera toujours le même quelque soit la taille de l'image à analyser. La deuxième hypothèse supposait que le système à base de règles fournirait certainement de meilleurs résultats que les méthodes à apprentissage par l'exemple. Les résultats obtenus dans cette étude confirment bien cette hypothèse.

La procédure proposée utilise une approche orientée objet (par région). Les résultats obtenus semblent montrer que l'approche classique par pixel n'est pas assez efficace. De plus, cette nouvelle approche permet d'élaborer des règles sur des critères géométriques. L'utilisation de cette approche paraît nécessaire si le travail de cette thèse s'oriente vers le développement d'un assistant en interprétation.

## 5.2. Limitations

Le système a été élaboré pour une utilisation dans un cadre général. La base de règles est spécifique à l'application. L'approche a été testée uniquement sur le site du Labrador et les données simulées. L'approche nécessite une étude pour établir certains éléments, comme les règles et le facteur de certitude. Le facteur de certitude est équivalent à la matrice de pondération pour les méthodes de fusion. Dans les travaux sur la fusion de données, on remarque que la matrice est difficile à estimer automatiquement, c'est pourquoi elle est généralement élaborée par l'utilisateur (Allard, 2001). Dans notre cas, à partir de tests, il est possible d'établir un poids (facteur de certitude) pour chaque règle. Une fois déterminés, les poids peuvent être conservés pour une application future de la base de règles.

La base de règles requiert la traduction de la connaissance en règles. Parfois, il est difficile d'élaborer de simples règles. Dans le cas de la détection du changement, la plupart des observations ont pu être traduites dans la base. Ceci n'est pas forcément vérifié pour d'autres applications. De plus, l'utilisateur doit connaître la syntaxe du langage CLIPS pour élaborer la base de connaissances. Face à ces contraintes, l'utilisateur pourrait alors être tenté d'utiliser une méthode à apprentissage par l'exemple. Malheureusement, les performances de ce genre de méthodes dépendent de l'ensemble d'exemples choisis. Effectivement, les exemples doivent pouvoir représenter un bon nombre de cas de figures de régions à identifier. Lorsque la scène est petite, il est parfois difficile de trouver suffisamment de régions.

## 5.3. Recommandations

Le système à base de règles peut être utilisé dans le cadre de la mise à jour d'une autre région. La procédure d'utilisation du système est expliquée dans l'annexe III. L'actualisation d'une carte est souvent répétée toutes les 3 années. L'approche permet de commencer la procédure de mise à jour avec la base de règles de la dernière mise à jour. Si les résultats sont probants alors aucune modification n'est nécessaire. Dans le cas contraire, l'interprète



peut ajouter une nouvelle règle ou modifier une ancienne. Par ailleurs, cette base de règles facilite la transmission de la connaissance (expertise) au sein d'une équipe. Elle est claire et, généralement, organisée selon des critères de classification. Ainsi, un interprète novice peut bénéficier du travail réalisé par une autre personne, parfois plus expérimentée.

## 5.4. Perspectives

Le travail de cette thèse peut être poursuivi dans plusieurs directions.

### 5.4.1. Erreurs dues aux corrections

Les erreurs dans les corrections radiométriques et géométriques n'ont pas été prises en compte dans les analyses de sensibilité. Nous avons émis l'hypothèse que les corrections n'affectaient pas la possibilité de relever les changements si elles étaient bien réalisées. En effectuant convenablement cette phase, les régions perturbées peuvent être identifiées avec une bonne précision. Il apparaît que cette phase est quand même délicate et des problèmes se sont manifestés dans l'étude. Des travaux futurs seraient nécessaires pour déduire la robustesse de la méthode face à ces problèmes.

### 5.4.2. Les images à très haute résolution spatiale

L'étude réalisée sur l'image à très haute résolution peut être encore améliorée. Les premiers résultats montrent le potentiel de la méthode. En effet, l'utilisation d'un système intelligent est certainement une avenue pour ce type d'image. L'étude réalisée ici n'est pas assez complète pour conclure fermement sur ce point. Les images à très haute résolution spatiale sont de plus en plus utilisées dans les projets ; cependant, peu d'outils sont disponibles pour ce type d'images (Metternicht, 1999; Sun, 1999; Quackenbush *et al.*, 2000; Palandro *et al.*, 2003). Il serait intéressant de consacrer une étude plus détaillée des approches proposées dans ce travail en utilisant une méthode de classification plus adaptée à la très haute résolution spatiale. En effet, la classification par la distance de Mahalanobis ne convient pas à



ce type de données. Un résultat de classification plus précis devrait permettre d'augmenter les performances de l'approche. La méthode de Voorons *et al.* (2003) sur les images Ikonos en milieu forestier serait intéressante à utiliser. Leur approche est basée sur une analyse multi-fractale de l'image permettant ainsi de retirer les caractéristiques locales de chaque région. Les classes forestières peuvent être extraites plus précisément.

### 5.4.3. L'analyse multirésolution

Une des orientations des méthodes de détection du changement est l'analyse multirésolution. Si une mise à jour nécessite la combinaison de données multirésolution, le problème de la résolution spatiale se pose. Peu de travaux se sont penchés sur ce problème au niveau de la détection du changement, mais il serait important d'y consacrer une étude. Le travail de Serra *et al.* (2003) semble intéressant à étudier car il illustre la possibilité d'associer dans une même procédure de détection du changement des données de résolutions spatiales différentes.

### 5.4.4. Plus d'informations

Pour la détection du changement, quelques informations ont été jugées pertinentes. Celles-ci étaient déjà utilisées dans la littérature. D'autres informations peuvent être ajoutées, notamment la texture. Les paramètres de texture associés à l'information spectrale permettent de mieux discriminer certains objets d'une scène (Franklin et Peddle, 1989; Kushwaha *et al.*, 1994; Ryherd et Woodcock, 1996). La plupart des paramètres sont déjà calculés sur les régions, mais la difficulté est de mettre en place des règles robustes pour tenir compte de cette information. Pour l'instant, il serait possible de mettre en place des règles simples sur les paramètres de texture. Il s'agit de comparer un paramètre de texture à un seuil. Cette approche est déjà utilisée par l'arbre de décision. Dans le système à base de règles, il faudrait certainement une technique différente. Par exemple, l'interprète pourrait définir un objet très texturé et un objet plutôt homogène dans la scène. Les règles devraient donc vérifier si la texture de la région à analyser est plus proche de l'un ou de l'autre.

#### 5.4.5. La création des règles

La création de la base de règles peut paraître assez compliquée. D'une part, il faut pouvoir exprimer sa connaissance sous la forme de simples règles. D'autre part, il faut traduire ces règles en langage CLIPS. Il est possible d'imaginer un module graphique qui permettrait à l'utilisateur de créer ces règles à l'aide de boîtes de dialogue. Des travaux ont commencé dans cette direction afin de permettre un accès plus commode au système.

Peu de travaux en intelligence artificielle envisagent ce type de module. En effet, il s'agirait de réaliser une sorte de traducteur du langage humain vers le langage CLIPS. Le développement d'un tel outil est assez complexe. Une solution serait de passer à travers une méthode automatique, comme l'arbre de décision ou le réseau de neurones, et de traduire la structure de ces méthodes en règles logiques. Des travaux existent dans la littérature sur ce point et ils facilitent l'utilisation des systèmes à base de règles (Huang et Jensen, 1997; Wlodzislaw *et al.*, 1997). Un travail a déjà débuté pour faciliter la construction de la base de règles à l'aide d'un arbre de décision. L'approche consiste à former l'arbre selon le travail de l'interprète et de restituer le résultat sous la forme de règles. Il serait important d'étudier différentes approches pour former la base de règles (arbre de décision ou réseau de neurones) et de vérifier la précision de ces approches sur les images à très haute résolution.

#### 5.4.6. Les règles floues

Le facteur de certitude représente bien le crédit que l'utilisateur accorde à une règle. Ce facteur peut paraître quelquefois trop rigide. Il serait intéressant d'introduire alors un degré dans la réponse de la règle en fonction de la certitude qu'un fait ou une condition soit réalisée. Par exemple, plus les conditions d'activation sont vérifiées, plus le degré de réponse de la règle est fort. La logique floue permet d'établir ce type de loi. Le système expert utilisé pour cette étude (JESS) permet d'introduire des règles floues grâce à une librairie spécialisée. Une étude serait nécessaire pour établir les performances de ce type de règles. Les articles de (Mascarilla,

1997; Hellmann et Jager, 2002; Lin et Yu, 2004) donnent des exemples d'application de ce type de règle.

#### **5.4.7. D'autres applications**

L'approche développée dans ce travail laisse entrevoir plusieurs autres applications possibles. L'identification des zones perturbées en milieu forestier est un cas particulier de la détection du changement. Elle pourrait être employée pour la cartographie des zones touchées par un désastre. Dans un tel contexte, le système permettrait de réduire le travail de l'interprète et, par conséquent, de fournir un document dans un bref délai.

Par ailleurs, le système pourrait être orienté vers le milieu urbain en modifiant uniquement la base de connaissances. Il serait alors capable de fournir une mise à jour de la carte d'occupation du sol. Dans ce cas, il réduirait la période de révision des documents cartographiques.

## 6. Références

- Abkar, A.-A., Sharifi, M. A., et Mulder, N. J. (2000). Likelihood-based image segmentation and classification : A framework for the integration of expert knowledge in image classification procedures. *ITC Journal - International Journal of Applied Earth Observation and Geoinformation*, vol. 2, n ° 2, p. 104–119.
- Aguado, I., Chuvieco, E., Martin, P., et Salas, J. (2003). Assessment of forest fire danger conditions in southern spain from noaa images and meteorological indices. *International Journal of Remote Sensing*, vol. 24, n ° 8, p. 1653–1668.
- Allard, Y. (2001). *Fusion d'informations multisources : application à la classification en milieu forestier*. Mémoire de maîtrise, Université de Sherbrooke.
- Arnold, R. H. (1997). *Interpretation of airphotos and remotely sensed imagery*. Prentice Hall, Upper Saddle River, N.J. Robert H. Arnold. ill., maps ; 28 cm.
- Atkinson, P. et Tatnall, A. (1997). Introduction neural networks in remote sensing. *International Journal of Remote Sensing*, vol. 18, n ° 4, p. 699–709.
- Bakker, W. (2002). Satellite imagery faq (satfaq). [http ://www.itc.nl/ bakker/satfaq/](http://www.itc.nl/bakker/satfaq/).
- Bannari, A., Morin, D., et Bonn, F. (1995). A review of vegetation indices. *Remote Sensing Reviews*, vol. 13, p. 95–120.
- Benediktsson, J. A. et Sveinsson, J. R. (1997). Feature extraction for multisource data classification with artificial neural networks. *International Journal of Remote Sensing*, vol. 18, n ° 4, p. 727–740.
- Breiman, L., Friedman, J. H., Olshen, R. A., et Stone, C. J. (1984). *Classification and Regression Trees*. Wadsworth.



Bruzzone, L., Prieto, D.-F., et Serpico, S. (1999). A neural-statistical approach to multi-temporal and multisource remote-sensing image classification. *IEEE Transactions on Geosciences and Remote Sensing*, vol. 37, n° 3, p. 1350–1359.

Canada, R. N. (2004). Système canadien d'information sur les feux de végétation. <http://cw-fis.cfs.nrcan.gc.ca/>.

Civco, D. L., Hurd, J. D., Wilson, E. H., Song, M., et Zhang, Z. (2002). A comparison of land use and land cover change detection methods. *ASPRS, 2002 ASPRS-ACSM Annual Conference and FIG XXII Congress*, p. –, Washington (USA).

Clement, V., Giraudon, G., Houzelle, S., et Sandakly, F. (1993). Interpretation of remotely sensed images in a context of multisensor fusion using a multispecialist architecture. *IEEE Transactions on Geosciences and Remote Sensing*, vol. 31, n° 4, p. 779–791.

Coppin, P. et Bauer, M. (1994). Processing of multitemporal landsat tm imagery to optimize extraction of forest cover change features. *IEEE Transactions on Geosciences and Remote Sensing*, vol. 32, n° 4, p. 918–927.

Coppin, P., Nackaerts, K., Queen, L., et Brewer, K. (2001). Operational monitoring of green biomass change for forest management. *Photogrammetric Engineering and Remote Sensing*, vol. 67, n° 5, p. 603–611.

Coppin, P. R. et Bauer, M. (1996). Digital change detection in forest ecosystems with remote sensing imagery. *Remote Sensing Environment*, vol. 13, p. 207–234.

Daryaei, J. (2003). Digital change detection using multi-scale wavelet transformation and neural network. Master's thesis, International Institute for Aerospace survey and Earth Sciences (ITC), Enschede, The Netherlands.

- Dubois, C. P., Zyl, J. V., et Engman, T. (1995). Measuring soil moisture with imaging radars. *IEEE Transactions on Geosciences and Remote Sensing*, vol. 33, n° 4, p. 915–926.
- Fau, R., Béné, G. B., Boucher, J. M., et He, D. C. (1994). Segmentation markovienne pyramidale d'images. *Journal Canadien de Télédétection*, vol. 20, n° 2, p. 150–155.
- Fernandez, A., Illera, P., et Casanova, J. L. (1997). Automatic mapping of surfaces affected by forest fires in Spain using AVHRR NDVI composite image data. *Remote Sensing Environment*, vol. 60, p. 153–162.
- Foody, G. (1997). An evaluation of some factors affecting the accuracy of classification by an artificial neural network. *International Journal of Remote Sensing*, vol. 18, n° 4, p. 799–810.
- Foresti, G. L. et Gentili, S. (2000). A vision based system for object detection in underwater images. *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 14, n° 2, p. 167–188.
- Foucher, S., Béné, G. B., et Boucher, J. M. (2001). Multiscale map filtering of SAR images. *IEEE Transaction On Image Processing*, vol. 10, n° 1, p. 49–60.
- Fournier, R. A., Edwards, G., et Eldridge, N. R. (1995). A catalogue of potential spatial discriminators for high spatial resolution digital images of individual crowns. *Journal Canadien de Télédétection*, vol. 21, n° 3, p. 285–298.
- Franklin, S. E. et Peddle, D. (1989). Spectral texture for improving class discrimination in complex terrain. *International Journal of Remote Sensing*, vol. 10, n° 8, p. 1437–1443.
- Fraser, R. H., Li, Z., et Cihlar, J. (2000). Hotspot and NDVI differencing synergy (HANDS) - a new technique for burned area mapping over boreal forest. *Remote Sensing of Environment*, vol. 74, n° 3, p. 362–376.

- Friedl, M. A. et Brodley, C. E. (1997). Decision tree classification of land cover from remotely sensed data. *Remote Sensing of Environment*, vol. 61, n ° 3, p. 399–409.
- Friedman-Hill, E. (2003). *JESS In Action*. Manning Publications.
- Fung, K. B., Goodenough, D. G., et Ryerson, R. (1993). The photo-interpretation keys expert system (pikes). *International Geoscience and Remote Sensing Symposium*, p. 177–182, Tokyo, Japan.
- Gagnon, F., de Saint-Félicien, C., et collégial de développement de matériel didactique, C. (1999). *L'interprétation des photographies aériennes : méthode et applications*. Centre collégial de développement de matériel didactique, [Montréal. France Gagnon. – ill. (certaines en coul.), cartes ; 28 cm "Ouvrage réalisé sous la responsabilité du Cégep de Saint-Félicien" Glossaire : p. 188-200.
- Germain, M., Béné, G. B., et Boucher, J. (2003). Fusion évidentielle multisource basée sur une nouvelle approche statistique floue. *AQT et CASI 25e Symposium canadien sur la télédétection*, Montréal (Canada).
- Goldberg, M., Goodenough, D. G., Alvo, M., et Karam, G. (1985). A hierarchical expert system for updating forestry maps with landsat data. IEEE, *IEEE Transactions on Geosciences and Remote Sensing*, vol. 73, p. 1054–1063.
- Goodenough, D. G., Robson, M., et Fung, K. B. (1989). Expert systems and environmental change - information extraction from remote sensing data. IEEE, *International Geoscience and Remote Sensing Symposium 1989, 12 th Canadian Symposium on Remote Sensing*, vol. 2, p. 823–828, Vancouver.
- Haapanen, R., Ek, A. R., Bauer, M. E., et Finley, A. O. (2004). Delineation of forest/nonforest land use classes using nearest neighbor methods. *Remote Sensing of Environment*, vol. 89, n ° 3, p. 265–271.

- Hame, T., Heiler, I., et Miguel-Ayanz, J. S. (1998). An unsupervised change detection and recognition system for forestry. *International Journal of Remote Sensing*, vol. 19, n° 6, p. 1079–1099.
- Hartog, J. d., Kate, T. t., et Gerbrands, J. (1996). Knowledge-based segmentation for automatic map interpretation. *Lecture Notes in Computer Science*, vol. 1072, p. 159–178.
- Hayes, D. J. et Sader, S. A. (2001). Comparison of change-detection techniques for monitoring tropical forest clearing and vegetation regrowth in a time series. *Photogrammetric Engineering and Remote Sensing*, vol. 67, n° 9, p. 1067–1075.
- Hellmann, M. et Jager, G. (2002). Fuzzy rule based classification of polarimetric sar data. *Aerospace Science and Technology*, vol. 6, n° 3, p. 217–232.
- Huang, X. et Jensen, J. R. (1997). A machine-learning approach to automated knowledge-base building for remote sensing image analysis with gis data. *Photogrammetric Engineering and Remote Sensing*, vol. 63, n° 10, p. 1185–1194.
- Huyck, C. K., Mansouri, B., Eguchi, R. T., Houshmand, B., Castner, L. E., et Shinozuka, M. (2002). Earthquake damage detection algorithms using optical and ers-sar satellite data - application to the august 17, 1999 marmara, turkey earthquake. *7th National US Conference on Earthquake Engineering*, Boston (USA).
- Jain, A., Ravan, S. A., Singh, R. K., Das, K. K., et Roy, P. (1996). Forest fire risk modeling using remote sensing and geographic information system. *Current Science*, vol. 70, n° 10, p. 928–932.
- Jiang, B. (2000). Agent-based approach to modelling urban and environmental systems within gis. *Proceedings of 9th International Symposium on Spatial Data Handling*, p. 1–12, Beijing (China).



- Kabanza, F., Bénéié, G., et Bourdua, D. (2000). Towards an intelligent system for environment monitoring. *International Symposium on Environmental Software Systems 2000*, Autriche.
- Kauth, R. et Thomas, G. (1976). The tasseled cap - a graphic description of the spectral-temporal development of agricultural crops as seen by landsat. *Proc. Symposium on Machine Processing of Remotly Sensed Data*, vol. 4B, p. 41–50.
- Kontoes, C. C., Raptis, V., Lautner, M., et Oberstadler, R. (2000). The potential of kernel classification techniques for land use mapping in urban areas using 5m-spatial resolution irs-1c imagery. *International Journal of Remote Sensing*, vol. 21, n ° 16, p. 3145–3151.
- Kushwaha, S. P. S., Kuntz, S., et Oesten, G. (1994). Applications of image texture in forest classification. *International Journal of Remote Sensing*, vol. 15, n ° 11, p. 2273–2284.
- Largouët, C. et Cordier, M.-O. (2001). Improving the landcover classification using domain knowledge. *Environmental Sciences and Artificial Intelligence*, vol. 14, n ° 1, p. 35–43.
- Lin, T.-C. et Yu, P.-T. (2004). Partition fuzzy median filter based on fuzzy rules for image restoration. *Fuzzy Sets and Systems*, vol. 147, n ° 1, p. 75–97.
- Liu, H. et Zhou, Q. (2004). Accuracy analysis of remote sensing change detection by rule-based rationality evaluation with post-classification comparison. *International Journal of Remote Sensing*, vol. 25, n ° 5, p. 1037–1050.
- Lloyd, C. D., Berberoglu, S., Curran, P. J., et Atkinson, P. M. (2004). A comparison of texture measures for the per-field classification of mediterranean land cover. *International Journal of Remote Sensing*, vol. 25, n ° 19, p. 3943–3966.
- Loh, D., Hsieh, Y.-T. C., Choo, Y. K., et Holtfrerich, D. R. (1994). Integration of a rule-based expert system with gis through a relational database management system for forest ressource management. *Computer and Electronics in Agriculture*, vol. 11, p. 215–228.

- Lorena, R. B., João Roberto, d. S., Shimabukuro, Y. E., Brown, I. F., et Hermann, J. H. K. (2002). A change vector analysis technique to monitor land use/land cover in sw bazilian amazon : Acre state. ISPRS, *Land Satellite Information IV Conference*, p. –, Denver (USA).
- Luque, S. S. (2000). Evaluating temporal changes using multi-spectral scanner and thematic mapper data on the landscape of a natural reserve : the new jersey pine barrens, a case study. *International Journal of Remote Sensing*, vol. 21, n ° 13, p. 2589–2611.
- Martin, M. E., Newman, S. D., Aber, J. D., et Congalton, R. G. (1998). Determining forest species composition using high spectral resolution remote sensing data. *Remote Sensing Environment*, vol. 65, p. 249–254.
- Mas, J.-F. (1999). Monitoring land-cover changes : a comparison of change detection techniques. *International Journal of Remote Sensing*, vol. 20, n ° 1, p. 139–152.
- Mascarilla, L. (1997). Fuzzy rules extraction and redundancy elimination : An application to remote sensing image analysis. *International Journal of Intelligent Systems*, vol. 12, n ° 11, p. 793–817.
- Matejek, S. (1997). *Méthode de mise à jour des cartes forestières en forêt privée à l'aide des images LANDSAT TM*. Mémoire de maîtrise, Université de Sherbrooke.
- Mayer, H. (1999). Automatic object extraction from aerial imagery – a survey focusing on buildings. *Computer Vision and Image Understanding*, vol. 74, n ° 2, p. 138–149.
- McKeown, D. M. (1996). Top ten lessons learned in automated cartography. Technical report, Digital Mapping Laboratory, School of Computer Science, Carnegie Mellon University.
- McKeown, D. M., Wilson, H. A., et McDermott, J. (1985). Rule-based interpretation of aerial imagery. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. PAMI-7, n ° 5, p. 570–585.

- Metternicht, G. (1999). Change detection assessment using fuzzy sets and remotely sensed data : an application of topographic map revision. *Journal of Photogrammetry and Remote Sensing*, vol. 54, p. 221–233.
- Müller, S. et Eickerler, S. (2001). An integrated approach to shape and color-based image retrieval of rotated objects using hidden markov models. *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 15, n ° 1, p. 223–237.
- Moller-Jensen, L. (1990). Knowledge-based classification of an urban area using texture and context information in landsat-tm imagery. *Photogrammetric Engineering and Remote Sensing*, vol. 56, n ° 6, p. 899–904.
- Moran, S. M., Vidal, A., Troufleau, D., Qi, J., Clarke, T. R., Pinter, P. J., Mitchell, T. A., Inoue, Y., et Neale, C. M. U. (1997). Combining multifrequency microwave and optical data for crop management. *Remote Sensing Environment*, vol. 61, p. 96–109.
- Muchoney, D. M. et Haack, B. N. (1994). Change detection for monitoring forest defoliation. *Photogrammetric Engineering and Remote Sensing*, vol. 60, n ° 10, p. 1243–1251.
- Mueller, M., Segl, K., et Kaufmann, H. (2004). Edge- and region-based segmentation technique for the extraction of large, man-made objects in high-resolution satellite imagery. *Pattern Recognition*, vol. 37, n ° 8, p. 1619–1628.
- Mulder, N. J., Middelkoop, H., et Miltenburg, J. W. (1991). Progress in knowledge engineering for image interpretation and classification. *Journal of Photogrammetry and Remote Sensing*, vol. 46, p. 161–171.
- MUNYATI, C. (2000). Wetland change detection on the kafue flats, zambia, by classification of a multitemporal remote sensing image dataset. *International Journal of Remote Sensing*, vol. 21, n ° 9, p. 1787–1806.

Neusch, T. et Sties, M. (1999). Application of the dubois-model using experimental synthetic aperture radar data for the discrimination of soil moisture and surface roughness. *Journal of Photogrammetry and Remote Sensing*, vol. 54, p. 273–278.

Northrop, D. P. (2005). *Notes de cours : Pattern Recognition and Expert Systems*. Dépt de Statistiques, 1 South Parks Road Oxford OX1 3TG, GB, université d'oxford edition.

Okhimamhe, A. A. (2003). Ers sar interferometry for land cover mapping in a savanna area in africa. *International Journal of Remote Sensing*, vol. 24, n ° 18, p. 3583–3594.

Palandro, D., Andrefouet, S., Dustan, P., et Muller-Karger, F. E. (2003). Change detection in coral reef communities using ikonos satellite sensor imagery and historic aerial photographs. *International Journal of Remote Sensing*, vol. 24, n ° 4, p. 873–878.

Patterson, M. W. et Yool, S. R. (1998). Mapping fire-induced vegetation mortality using landsat thematic mapper data : a comparison of linear transformation technique. *Remote Sensing Environment*, vol. 65, p. 132–142.

Quackenbush, L. J., Hopkins, P. F., et Kinn, G. J. (2000). Developing forestry products from high resolution digital aerial imagery. *Photogrammetric Engineering and Remote Sensing*, vol. 66, n ° 11, p. 1337–1346.

Quinlan, R. (1986). Induction of decision trees. *Machine Learning*, vol. 1, n ° 1, p. 81–106.

Raney, B. et Nagel, K. (2003). An agent-based simulation model of swiss travel : First results. *3rd SwissTransport Research Conference*, Monte Verita (Switzerland).

Rollet, R., Bénié, G., Li, W., Wang, S., et Boucher, J. (1998). Image classification algorithm based on the rbf neural networks and k-means. *International Journal of Remote Sensing*, vol. 19, n ° 15, p. 3003–3009.



Rousseau, K., Béné, G. B., Kabanza, F., et Beauchemin, M. (2002). An expert system for selecting remote sensing imagery. IEEE, *International Geoscience and Remote Sensing Symposium 2002*, vol. 3, p. 1343–1345, Toronto (Canada).

Roy, P., Sharma, K., et Jain, A. (1996). Stratification of density in dry deciduous forest using satellite remote sensing digital data - an approach based on spectral indices. *Journal Bioscience*, vol. 21, n° 5, p. 723–734.

Russell, S. J. et Norvig, P. (2003). *Artificial intelligence : a modern approach*. Upper Saddle River : Prentice Hall, c2003., USA. contributing writers, John F. Canny ... [et al.].

Ryherd, S. et Woodcock, C. (1996). Combining spectral and texture data in the segmentation of remotely sensed images. *Photogrammetric Engineering and Remote Sensing*, vol. 62, n° 2, p. 181–194.

Salas, W. A., Ducey, M. J., Rignot, E., et Skole, D. (2002). Assessment of jers-1 sar for monitoring secondary vegetation in amazonia : II. spatial, temporal, and radiometric considerations for operational monitoring. *International Journal of Remote Sensing*, vol. 23, n° 7, p. 1381–1399.

Serra, P., Pons, X., et Sauri, D. (2003). Post-classification change detection with data from different sensors : some accuracy considerations. *International Journal of Remote Sensing*, vol. 24, n° 16, p. 3311–3340.

Sester, M. (2000). Knowledge acquisition for the automatic interpretation of spatial data. *International journal of Geographical Information Science*, vol. 14, n° 1, p. 1–24.

Skidmore, A. K., Watford, F., Luckananurug, P., et Ryan, P. J. (1996). An operational gis expert system for mapping forest soils. *Photogrammetric Engineering and Remote Sensing*, vol. 62, n° 5, p. 501–510.

Soh, L.-K., Tsatsoulis, C., Gineris, D., et Bertoia, C. (2004). Arktos : An intelligent system for sar sea ice image classification. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42, n ° 1, p. 229–248.

Stefanov, W. L., Ramsey, M. S., et Christensen, P. R. (2001). Monitoring urban land cover change - an expert system approach to land cover classification of semiarid to arid urban centers. *Remote Sensing of Environment*, vol. 77, n ° 2, p. 173–185.

Sun, W. (1999). *A New Information Fusion Method for Land-Use Classification Using High Resolution Satellite Imagery*. PhD thesis, Johannes Gutenberg-Universität.

Tokola, T., Lofman, S., et Erkkila, A. (1999). Relative calibration of multitemporal landsat data for forest cover change detection. *Remote Sensing of Environment*, vol. 68, n ° 1, p. 1–11.

Ton, J., Sticklen, J., et Jain, A. (1991). Knowledge-based segmentation of landsat images. *IEEE Transactions on Geosciences and Remote Sensing*, vol. 29, n ° 2, p. 222–232.

Tsatsoulis, C. (1993). Expert systems in remote sensing applications. *IEEE Geoscience and Remote Sensing Society Newsletter*, vol. June, p. 7–15.

Voorons, M., Germain, M., Bénié, G., et Fung, K. (2003). Segmentation of high resolution images based on the multifractal analysis. IEEE, *International Geoscience and Remote Sensing Symposium 2003*, Toulouse (France).

Walter, V. (2004). Object-based classification of remote sensing data for change detection. *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 58, n ° -, p. 225–238.

Witten, I. H. et Frank, E. (October 1999). *Data Mining : Practical machine learning tools with Java implementations*. Morgan Kaufmann, San Francisco.

Wlodzislaw, D., Adamczak, R., et Grabczewski, K. (1997). Extraction of crisp logical rules using constrained backpropagation networks. *International Conference on Artificial Neural Networks (ICNN97)*, Houston (USA).

Zhou, Z.-H., Jiang, Y., et Chen, S.-F. (2003). Extracting symbolic rules from trained neural network ensembles. *AI Communications*, vol. 16, n ° 1, p. 3–15.

# Annexe I : La base de connaissances pour la moyenne résolution au Labrador

Les règles explicites pour les trois types de changement sont :

Règle 1 : si une région est trouvée à proximité d'un échantillon "coupe" identifiée et qu'elle a les mêmes caractéristiques spectrales alors c'est possiblement une coupe.

Règle 2 : si une autre coupe est découverte dans le voisinage de la région analysée alors c'est possiblement une coupe.

Règle 3 : si une route est découverte à proximité de la région analysée alors c'est possiblement une coupe.

Règle 4 : une ancienne forêt mixte peut devenir une coupe.

Règle 5 : une ancienne forêt conifère dense peut devenir une coupe.

Règle 6 : une ancienne forêt conifère peu dense peut devenir une coupe.

Règle 7 : si l'indice NDVI d'une ancienne zone forestière est faible alors c'est possiblement une coupe.

Règle 8 : si l'indice ARVI d'une ancienne zone forestière est faible alors c'est possiblement une coupe.

Règle 9 : si l'indice greenness d'une ancienne zone forestière est faible alors c'est possiblement une coupe.



Règle 10 : si l'indice brightness d'une ancienne zone forestière est fort alors c'est possiblement une coupe.

Règle 11 : une coupe a une compacité proche de 1.

Règle 12 : une coupe ne peut pas apparaître après une zone marécageuse.

Règle 13 : une coupe ne peut pas apparaître après une zone d'exploitation non commerciale.

Règle 14 : une coupe ne peut pas apparaître après une zone en friche.

Règle 15 : si une région est trouvée à proximité d'un échantillon "coupe" identifiée et qu'elle a les mêmes caractéristiques spectrales alors c'est possiblement une coupe.

Règle 16 : si une région est trouvée à proximité d'un échantillon "site en régénération" identifiée et qu'elle a les mêmes caractéristiques spectrales alors c'est possiblement un site en régénération.

Règle 17 : si un site en régénération est découvert dans le voisinage de la région analysée alors c'est possiblement un site en régénération.

Règle 18 : si une route est découverte à proximité de la région analysée alors c'est possiblement un site en régénération.

Règle 19 : une ancienne coupe peut devenir un site en régénération (stade 1).

Règle 20 : une ancienne coupe peut devenir un site en régénération (stade 1).

Règle 21 : si l'indice NDVI d'une ancienne coupe est fort alors c'est possiblement un site en régénération.

Règle 22 : si l'indice ARVI d'une ancienne coupe est fort alors c'est possiblement un site en régénération.

Règle 23 : si l'indice Greenness d'une ancienne coupe est fort alors c'est possiblement un site en régénération.

Règle 24 : si l'indice Brightness d'une ancienne coupe est faible alors c'est possiblement un site en régénération.

Règle 25 : un site en régénération ne peut pas apparaître après une zone marécageuse.

Règle 26 : un site en régénération ne peut pas apparaître après une zone d'exploitation non commerciale.

Règle 27 : un site en régénération ne peut pas apparaître après une zone en friche.

Règle 28 : un site en régénération (stade 2) apparaît après un site en régénération (stade 1).

Règle 29 : les régions changées de petite taille dont la classe est très différente du voisinage sont possiblement des erreurs causées par la procédure.

## Annexe II : Quelques exemples de règles en CLIPS

### Règle sur un attribut

```
(defrule prob-recent-oldforest-ndvilow
  (declare (salience 20))
  ?f<-(object (number ?number)(oldclassName mixed|dense|open|shrub)(ndvi ?ndvi))
  (test (< ?ndvi ?*ndvilow*))
=>
  (probClassSeg "store" ?number recent (* ?*conf-ndvi* 0.8))
)
```

Traduction :

Si l'objet analysé est une ancienne classe forestière et que son indice NDVI est faible alors c'est probablement une coupe.

### Règle sur l'occupation du sol

```
(defrule prob-recent-oldforest
  (declare (salience 20))
  ?f<-(object (number ?number) (oldclassName mixed|dense|open|shrub))
=>
  (probClassSeg "store" ?number recent (* ?*conf-transi* 0.2))
)
```

Traduction :

Une coupe succède souvent à une classe forestière.

## Règles sur les sites d'entraînement

```
((defrule samples-location-near
  (declare (salience 20))
  ?f<-(object (number ?number) (centerObj TRUE) (xc ?xc) (yc ?yc))
=>
  (checksamples "dist" ?number ?xc ?yc 1000)
)

(defrule samples-location-near-print
  (declare (salience 20))
  ?f<-(checkspec ?number ?classname ?class)
  ?f2<-(object (number ?number) (band $?bd) (centerObj TRUE))
=>
  (bind ?distTmp (statCalculator "verifyNeighClass" ?class $?bd))
  (if (> 1 ?distTmp)
    then
    (assert (prob-class ?number ?classname (* ?*conf-samples* 0.8) 0))
  )
  (retract ?f)
)
```

Traduction :

Ces deux règles vérifient la localisation des sites d'entraînement et en même temps les caractéristiques spectrales.

La première règle sélectionne les sites à proximité de l'objet analysé (dans ce cas, 1000 pixels de distance). La deuxième règle vérifie que la distance entre les caractéristiques spectrales du site et de l'objet est faible (distance de Mahalanobis). Si c'est vrai alors l'objet peut avoir la même classe que le site.

## Règle sur le contexte spatial

```
(defrule neighb-class
  (declare (salience 20))
  ?f1<-(object (number ?number))
  ?f2<-(object (number ?number1) (className ?class))
=>
```



```
(probClassSeg "store" ?number ?class (* ?*conf-neigh* 0.8))  
(retract ?f2)  
)
```

Traduction :

L'objet analysé peut être de la même nature qu'un objet dans le voisinage.

# Annexe III : Manuel pour le logiciel d'interprétation assistée par un système intelligent

La procédure pour utiliser le système s'effectue en plusieurs étapes. Les étapes sont détaillées dans la suite du chapitre.

## Préparation des données

L'image à interpréter doit être dans un format accepté par le logiciel SITI. Les formats utilisés sont TIFF, PGM, BMP, JPEG. En général, le format TIFF convient mieux aux images satellitaires. Il gère de nombreuses couches d'information, notamment les coordonnées géographiques avec GEOTIFF.

L'image peut être corrigée des effets atmosphériques et radiométriques. Cette correction est nécessaire, si vous comptez utiliser la réflectance pour identifier les régions. Le système fonctionne aussi sans ces corrections.

## Chargement des données

Dans un premier temps, il est nécessaire d'ouvrir l'image à interpréter. L'interface SITI est développée en JAVA avec les bibliothèques d'imagerie JAI de SUN. Le logiciel offre une bonne gestion de la mémoire et permet l'utilisation d'images de grande taille. Dans un deuxième temps, l'image doit être découpée en objets. Les objets sont obtenus grâce à un résultat de segmentation. De nombreuses méthodes sont disponibles sous l'interface SITI, mais le système accepte un résultat d'une méthode externe (figure 6.1).

La segmentation doit être composée d'une seule bande. Cette image sera alors utilisée pour définir les régions de la scène.

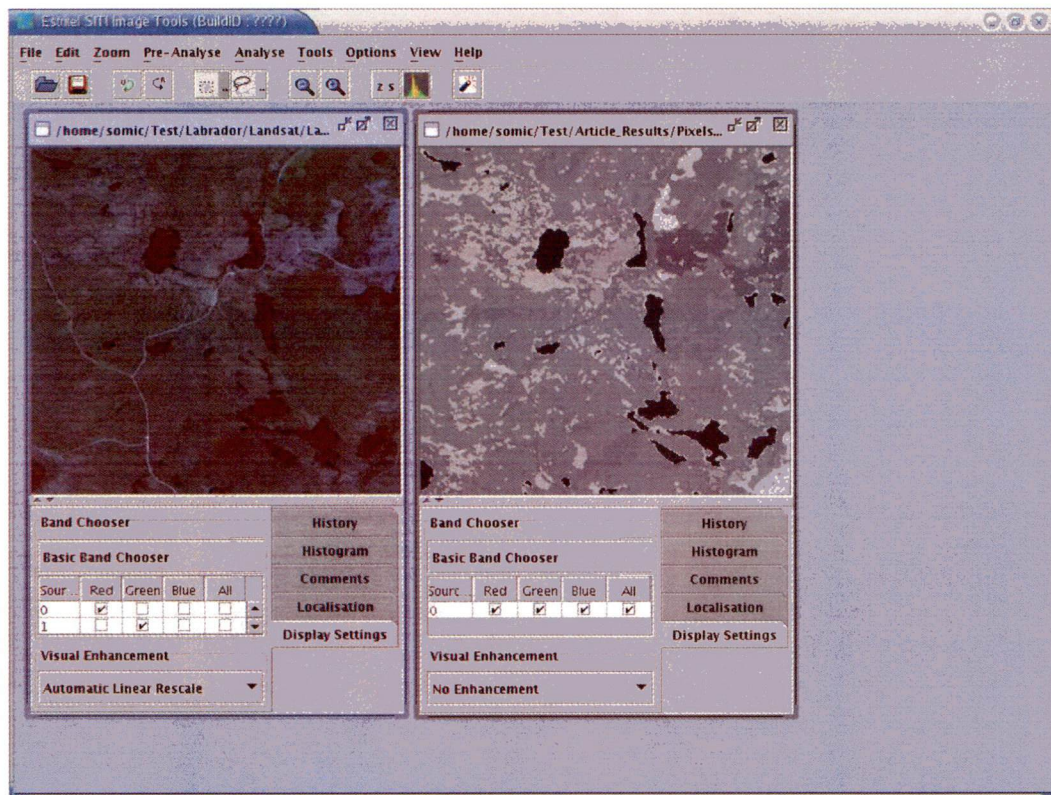


Figure 6.1: Chargement des images

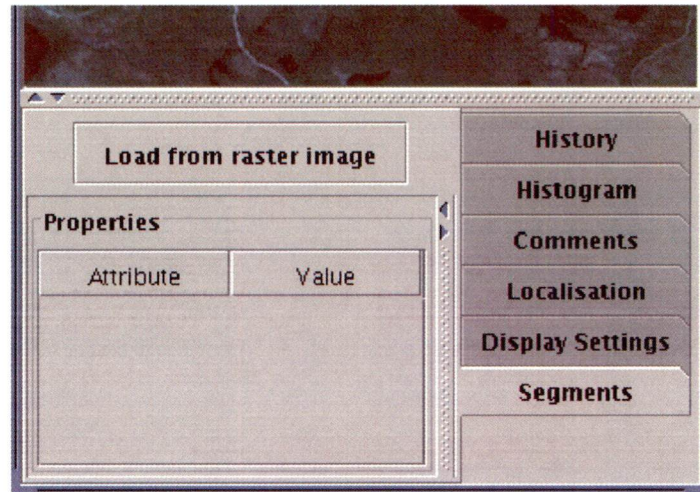


Figure 6.2: Onglet pour la description

## Description des régions

L'étape suivante est de découper la scène à interpréter en région à l'aide de la segmentation. Pour cela, il faut utiliser le menu *Analyse -> Intelligent Analyser -> Process Description*. Le résultat de cette action est l'apparition d'un onglet en dessous de l'image (figure 6.2). Le bouton *Load from raster image* de l'onglet permet de charger l'image segmentée. Pour cela, choisissez l'image correspondant au résultat de segmentation dans le sélecteur d'images.

Les prochaines étapes concernent les choix relatifs à la description des régions. D'abord il faut choisir si les régions doivent être numérotées. Dans notre cas, il est nécessaire de numéroté les régions, car il est important qu'un numéro unique corresponde à une région. Ensuite, il faut choisir si des paramètres de texture et des indices de végétation doivent être calculés pour chaque région.

### La texture

6 paramètres de texture peuvent être calculés pour chaque région. La procédure n'est pas forcément nécessaire, si vous pensez que la texture est inutile pour l'identification des régions. L'assistant appelle une fonctionnalité de l'interface principale. La procédure est expliquée plus en profondeur dans le manuel de l'interface SITL.



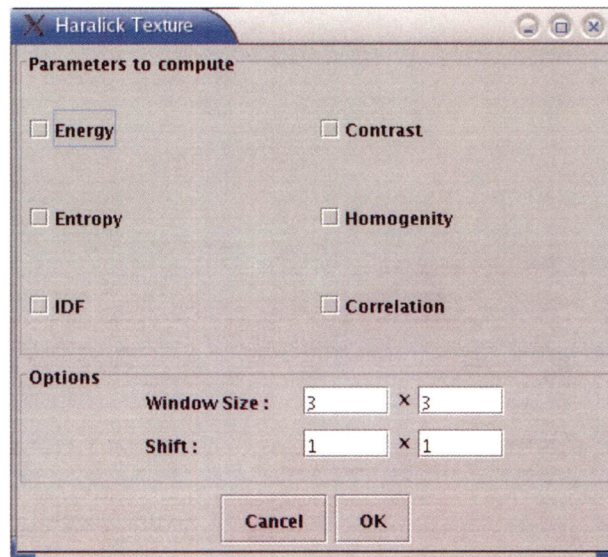


Figure 6.3: Choix des paramètres

## Les indices de végétation

De nombreux indices de végétation sont disponibles dans l'interface principale. Cette information peut être intéressante dans la discrimination de certaines zones végétales.

Le système fonctionne aussi sans les paramètres de texture et les indices de végétation.

## Utilisation de l'onglet

Une fois la description réalisée, l'onglet *Segment* permet d'obtenir les caractéristiques de chaque région. Il suffit alors de sélectionner une région de l'image pour que l'information s'affiche dans l'onglet. Cette information permet à l'interprète de reconnaître certaine région. La région sélectionnée apparaît en rouge sur l'image (figure 6.5).

## Chargement des données complémentaires

### Les sites d'entraînement

Les sites doivent être sous la forme d'une image. L'image comporte des sites d'entraînement colorés et un fond noir. L'image est chargée en suivant la procédure suivante *Analyse - > Analyseur Intelligent -> Charger des sites d'entraînement*. Il faut alors choisir l'image

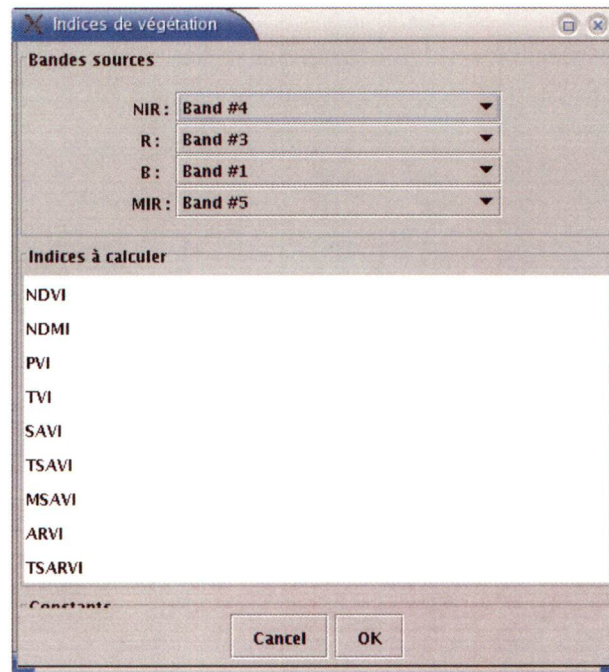


Figure 6.4: Les indices de végétation

correspondante dans la liste proposée. Ensuite, il faut sélectionner l'image comprenant les bandes spectrales pour le calcul des statistiques.

### La définition de la légende

Il est important de définir les classes présentes dans la scène. Un module spécial permet cette gestion et il est accessible à partir de ces menus *Analyse -> Analyseur Intelligent -> Éditer la table des couleurs*. Il est possible de charger une légende déjà existante.

Cette opération permet d'attribuer une couleur à chaque classe présente dans l'image. Le résultat de l'interprétation respectera cette légende.

### Les données thématiques

Le module servant à la mise à jour d'une ancienne carte, il est nécessaire d'introduire l'ancienne carte et la nouvelle carte. À partir de ces deux informations, le système analyse les changements.

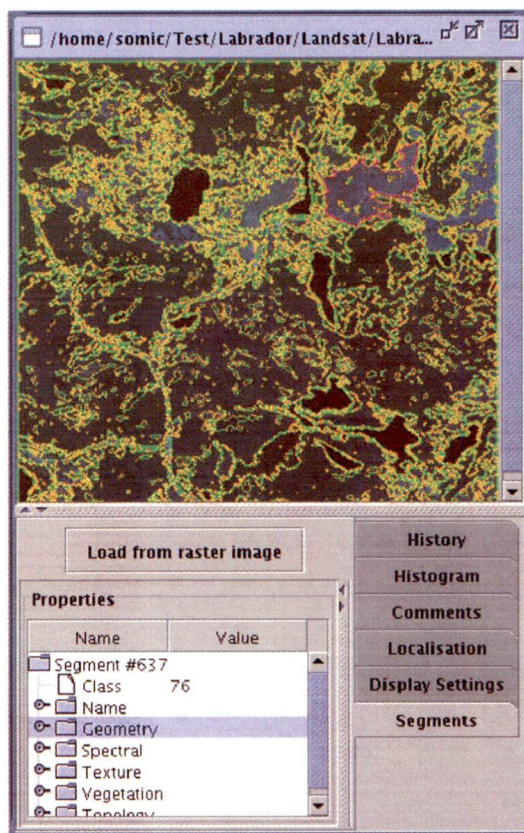


Figure 6.5: Sélection d'une région

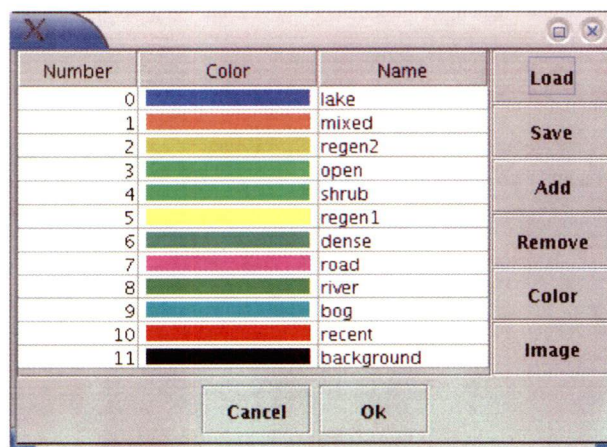
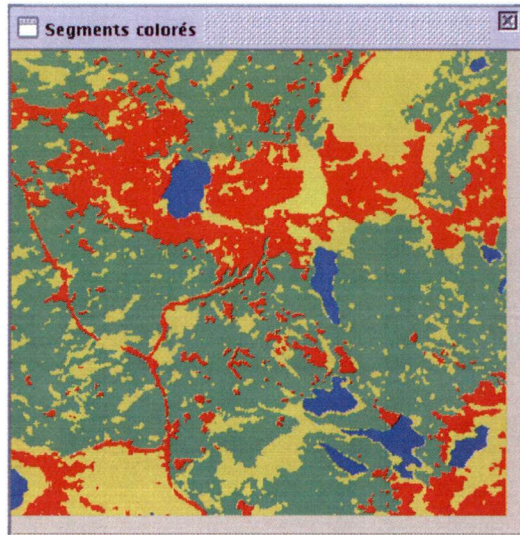


Figure 6.6: Éditeur de légende





**Figure 6.7: Un résultat**

La fenêtre de dialogue est disponible en suivant la procédure suivante *Analyse -> Analyseur Intelligent -> Ajouter des données auxiliaires*. Il faut alors sélectionner l'image correspondante à chaque information.

## Chargement de la base de connaissances

Une fois que toutes les données ont été chargées dans la mémoire du système, une base de connaissance peut être appliquée. Cette base se trouve sous la forme d'un fichier *CLIPS*. Il suffit donc de sélectionner le fichier correspondant au travail à réaliser. La base peut donc être spécialisée pour un type de capteur et une région particulière. L'intérêt de cette approche est de limiter le nombre de règles dans le système, ce qui réduit le temps de raisonnement. Utiliser la procédure suivante pour charger la base de connaissance : *Analyse -> Analyseur Intelligent -> Système expert -> Charger le fichier de règles*. Une fois la base chargée, le système peut commencer son analyse. Pour lancer le système, *Analyse -> Analyseur Intelligent -> Système expert -> Envoyer la description à JESS*.

## Résultat de l'interprétation

À la fin de l'analyse, le système fournit le résultat de l'interprétation (figure 6.7). De plus, un rapport sur l'interprétation est réalisé ainsi qu'une carte de confiance.